

Aplicación de Redes Neuronales para la Predicción de Sequías en el Norte de la Ciudad de México

Yunue Garza-Pimentel, Marcos Ángel González-Olvera, Jaime Reynaldo Santos-Reyes

Institución: Instituto Politécnico Nacional, Universidad Nacional Autónoma de México.

Email: , ygarzap2200@alumno.ipn.mx, marcos.angel.gonzalez@uacm.edu.mx, jsantosr@ipn.mx

URL ORCID: <https://orcid.org/0009-0001-2080-5776>, <https://orcid.org/0000-0001-8174-4391>, <https://orcid.org/0000-0002-3758-9862>

Resumen— Este estudio presenta el desarrollo de un modelo de Redes Neuronales Artificiales (RNA) para predecir sequías en el norte de la Ciudad de México a partir de datos meteorológicos históricos. El enfoque se centra en la limpieza, normalización y análisis de datos para construir un modelo robusto capaz de identificar patrones climáticos relevantes. Se evalúa el desempeño del modelo en diferentes horizontes temporales, mostrando alta precisión a corto plazo, con la evaluación de sus limitaciones en predicciones a mediano y largo plazo. Los resultados resaltan la utilidad de las RNA en la gestión de recursos hídricos y destacan la importancia de mejorar las estrategias de modelado incorporando variables adicionales en futuros trabajos.

Palabras Clave — Redes Neuronales Artificiales, predicción de sequías, aprendizaje automático, índices de sequía, modelado climático.

Abstract - This study presents the development of an Artificial Neural Network (ANN) model to predict droughts in northern Mexico City from historical meteorological data. The approach focuses on data cleaning, normalization, and analysis to build a robust model capable of identifying relevant climate patterns. The performance of the model is evaluated over different time horizons, showing high short-term accuracy, with the assessment of its limitations in medium- and long-term predictions. The results highlight the utility of ANNs in water resource management and underline the importance of improving modeling strategies by incorporating additional variables in future work.

I. INTRODUCCIÓN

La sequía representa una ocurrencia natural que se manifiesta a través de diversas condiciones climáticas y es uno de los desafíos naturales más importantes que enfrentamos, lo que lleva a considerables impactos económicos, sociales y ambientales [1]. Este evento puede verse como una situación en la que no hay suficiente agua durante un período prolongado debido a una escasez en los suministros, superficiales o de agua subterránea. Las repercusiones de la sequía son profundamente perjudiciales para la agricultura, la accesibilidad al agua, los ecosistemas y la economía en general, presentando así un desafío formidable en el ámbito de la gestión de los recursos hídricos [2], [3]. Las técnicas avanzadas de predicción de lluvia, impulsadas por inteligencia artificial y aprendizaje automático, están transformando la planificación urbana y la gestión de infraestructura. Modelos como Prep-SeqNet, con una precisión

de hasta el 95.9%, permiten anticipar con mayor certeza eventos climáticos extremos, lo que facilita la toma de decisiones en emergencias, desde la organización de evacuaciones hasta la distribución de recursos [4]. Además, estas predicciones ayudan a diseñar sistemas de drenaje más eficientes y estructuras robustas que minimizan el riesgo de inundaciones. No obstante, su implementación requiere inversión en tecnología y capacitación, lo que puede ser un reto para ciudades con recursos limitados [5], [6].

Entre las estrategias probadas para la predicción de sequías, tanto en México como a nivel mundial se han probado [7], [8]. Entre ellas, las redes neuronales entrenadas con datos meteorológicos históricos han mostrado resultados prometedores, ya que aprovechan los datos históricos que proveen diversos índices de sequía, empleando técnicas de aprendizaje automático para mejorar la precisión de los pronósticos. En México, particularmente en regiones como Zacatecas, se han utilizado Redes Neuronales Artificiales (ANN) para pronosticar índices de sequía, mostrando alta precisión con valores de R^2 que van de 0.834 a 0.988 para el Índice de Sequía de Reconocimiento (IDR) [9]. En este sentido ampliar el estudio permitirá evaluar la precisión y adaptabilidad de las RNA en distintas regiones, considerando variabilidad climática y geográfica para una mejor aplicabilidad nacional.

Por lo anterior, en este estudio se propone el desarrollo y evaluación de un modelo de basado en Redes Neuronales Artificiales (RNA) con en una arquitectura de perceptrón multicapa para predecir la sequía en la zona norte de la Ciudad de México. Para evaluar su precisión, se analiza su desempeño en la predicción de sequías utilizando los índices SPI, SPEI y RDI en horizontes temporales de 3, 6 y 12 meses [9]. Además, se busca identificar cuál de estos índices es mejor representado por el modelo de RNA, con el fin de determinar cuál es el más adecuado para la predicción de sequías en regiones semiáridas con características similares al área de estudio. La combinación del modelo RNA con el índice de sequía más representativo podría mejorar significativamente la capacidad de pronóstico de sequías y contribuir al desarrollo de estrategias más eficaces para la gestión del agua en estas regiones [10].

II. METODOLOGÍA/DESARROLLO

A. Selección de Datos y Zona de Estudio

Para replicar el análisis, se seleccionó una zona representativa de la Ciudad de México, específicamente una zona con alta densidad poblacional y problemas urbanos bien documentados. La zona seleccionada corresponde a la alcaldía Gustavo A. Madero ubicada al norte de la ciudad, la cual es conocida por su alta demanda de transporte y servicios públicos [11]. La Ciudad de México enfrenta una distribución desigual del agua, con marcadas diferencias en el estrés hídrico entre sus zonas norte y sur. Mientras que las áreas residenciales, predominantemente en el sur, reciben aproximadamente 7,567 litros diarios por hogar, las zonas populares del norte apenas alcanzan los 124 litros diarios. Esta disparidad se debe, en parte, a la menor recarga de acuíferos subterráneos en el norte y a una demanda de agua que supera la capacidad de suministro local. Predecir la sequía en la zona norte es crucial para implementar estrategias que mitiguen el estrés hídrico existente y aseguren un abastecimiento equitativo para todos los habitantes de la ciudad [12].

Los datos utilizados en este estudio fueron recopilados de la página oficial del Servicio Meteorológico Nacional de México, específicamente de la estación climática Gran Canal (9029), los cuales son públicos y gratuitos dichos datos fueron procesados y limpiados para ser utilizados como entradas en las redes neuronales. La serie de datos abarca un período de 52 años, desde 1961 hasta 2012 [11]. La selección de los datos se realizó considerando tres criterios clave para garantizar la calidad del estudio: la estación meteorológica debía estar operativa, los registros debían cubrir al menos 50 años de datos y no podía haber más del 15% de datos faltantes en la estación. Antes de realizar el análisis de sequía, se imputaron los valores ausentes y se verificó la consistencia de la serie de datos atmosféricos [9].

La precisión en la predicción de sequías depende de la calidad de los datos meteorológicos históricos, ya que conjuntos de datos completos y la inclusión de precipitación rezagada mejoran el rendimiento del modelo al capturar mejor las tendencias temporales [13], [14]. Las redes neuronales, como los modelos de Redes Neuronales Artificiales (ANN) y de Memoria a Largo Plazo (LSTM), han demostrado una alta precisión en la predicción de índices de sequía como SPI (Índice Estandarizado de Precipitación), SPEI (Índice Estandarizado de Precipitación y Evotranspiración) y DRI (Índice de Reconocimiento de Sequía), con métricas de rendimiento que indican fuertes correlaciones entre los valores predichos y real [15], [16].

B. Procesamiento, Entrenamiento y Evaluación del Modelo

Los datos fueron normalizados y transformados en un formato que pudiera ser utilizado por las redes neuronales. Posteriormente, se entrenó el modelo utilizando 624 datos

correspondientes a los 52 años, para ajustar los parámetros de la red y minimizar el error de predicción se programó 3 neuronas de entrada y de salida (correspondiente al número de meses) con una capa oculta de 20 neuronas. Se emplearon técnicas de validación cruzada para evaluar la precisión del modelo [9], [11]. La entrada del modelo se compone de un conjunto de valores históricos de la variable climática en función del mes k , representado como $in = [x(k), x(k-1), x(k-2), \dots, x(k-n)]$, donde n varía según el horizonte temporal considerado (3, 6 o 12 meses). La salida out corresponde al valor de la variable en el mes siguiente, es decir, $out = x(k+1)$.

El modelo requiere la optimización de hiperparámetros, incluyendo la cantidad de neuronas, la arquitectura de capas ocultas, el número de épocas de entrenamiento, la elección del optimizador, y la selección de la función de pérdida. Ejecutándose a través de un proceso de calibración, que abarca las fases de capacitación y validación [9], [17]. El refinamiento del modelo se logra utilizando un algoritmo de optimización basado en los principios de descenso de gradiente; sin embargo, existe el potencial de sobreajuste si el modelo se sintoniza demasiado con instancias particulares en lugar de lograr una generalización más amplia. Para mitigar este riesgo, se emplea la técnica de parada temprana, que termina el proceso de capacitación tras la identificación del sobreajuste [9], [18].

La fase final del desarrollo del modelo implica evaluar su eficacia predictiva. Se emplearon cuatro indicadores estadísticos para cuantificar la efectividad del modelo: el Coeficiente de Determinación (R^2), el Error Cuadrático Medio (MSE) la Raíz del Error Cuadrático Medio (RMSE), el Error Medio Absoluto (MAE) y el Error Medio de Sesgo (MBE) , [19], [20]. Estos indicadores se definen como:

R^2 (Coeficiente de Determinación): mide la proporción de la varianza en la ajustándose al modelo a los datos reales. Su fórmula es:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

Donde:

y_i es el valor observado.

\hat{y}_i es el valor predicho.

\bar{y} es la media de los valores observados.

Error Cuadrático Medio (MSE): es el promedio de los errores al cuadrado entre los valores observados y los predichos, ofrece una medida global de la precisión del modelo. Su fórmula es:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Error Absoluto Medio (MAE): calcula el promedio de las diferencias absolutas entre los valores observados y predichos, proporcionando una medida directa del error. Su fórmula es:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

Error Medio de Sesgo (MBE): calcula el promedio de las diferencias absolutas entre los valores observados y predichos. Su fórmula es:

$$MBE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) \quad (4)$$

Raíz del Error Cuadrático Medio (RMSE): es la raíz cuadrada del MSE. Devuelve la métrica de la unidad original. Su fórmula es:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

Se utilizó MATLAB R2023a para completar los datos faltantes, verificar la consistencia de las series de precipitación y temperatura, y calcular tanto la Evapotranspiración Potencial (ETP) como los tres índices de sequía. El modelo de red neuronal artificial (ANN), que demostró un desempeño superior de acuerdo con estos indicadores, fue elegido en última instancia como el modelo definitivo para pronosticar condiciones de sequía [9].

III. RESULTADOS Y DISCUSIÓN

El modelo de redes neuronales entrenado mostró: 0.927 para la escale de 3 meses, 0.867 para la escale de 6 meses y de 0.825 para la escale de 12 meses.

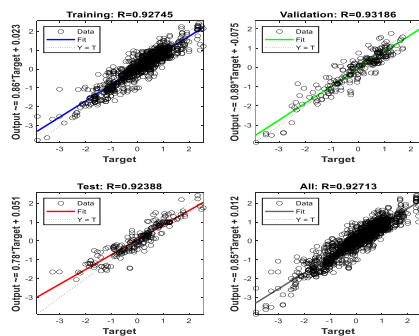


Figura 1.- Diagrama de dispersión (SPEI), a tres meses.

La Figura 1 ejemplifica el comportamiento de los datos predichos y observados en la red neuronal. Por su parte, los resultados mostrados en la Tabla 1 revelan que el modelo de red neuronal tiene un buen desempeño en el horizonte de 3 meses (SPEI-3) con un R^2 de 0.649, MSE de 0.280, MAE de 0.406, MBE de 0.080 y RMSE de 0.525. Para 6 meses (SPEI-6), el R^2 disminuye a 0.449 y se observan incrementos en los errores (MSE de 0.442, MAE de 0.531 y RMSE de 0.664),

manteniéndose un sesgo bajo (MBE de 0.046). En contraste, para 12 meses (SPEI-12) el modelo presenta un desempeño deficiente, evidenciado por un R^2 negativo (-0.050) y los mayores valores de error (MSE de 0.661, MAE de 0.647, MBE de 0.142 y RMSE de 0.812). En la Figura 2 se muestran, por motivos de espacio, únicamente los resultados obtenidos en la predicción con un horizonte de tres meses.

Estos resultados sugieren que, si bien el modelo es adecuado para predicciones a corto plazo (3 meses), su desempeño se ve comprometido en horizontes temporales más largos, lo que destaca la importancia de ajustar las estrategias de modelado según el horizonte de predicción deseado.




Figura 2.- Diagrama de predicción (SPEI), a tres meses.

Asimismo, estos indican que las redes neuronales son herramientas efectivas para la toma de decisiones urbanas, ya que proporcionan información clave para la planificación de infraestructura, la optimización del tráfico y la distribución de recursos en áreas densamente pobladas, dada su capacidad para procesar grandes volúmenes de datos en tiempo real facilita la gestión de emergencias y crisis. Sin embargo, la precisión del modelo depende en gran medida de la calidad de los datos, y la falta de información precisa en ciertas zonas, así como de dinámicas inherentes al proceso que, dado su origen aleatorio, no son del todo replicadas por el modelo. Además, dado que el estudio se centra en un conjunto limitado de variables, esto pudiera reducirse al incorporar más variables, o bien, emplear estructuras optimizadas para mejorar la precisión de la predicción.

IV. CONCLUSIONES

El uso de redes neuronales en el análisis urbano ofrece un gran potencial para mejorar la planificación y gestión de las ciudades. A través de este estudio de caso en la Ciudad de México, se comprobó que las redes neuronales pueden ser eficaces en la identificación de patrones urbanos y en la predicción de eventos futuros a corto plazo, específicamente en horizontes de hasta tres meses. Sin embargo, el desempeño del modelo se ve comprometido en predicciones a más largo plazo, lo que sugiere la necesidad de ajustar las estrategias de modelado. Para mejorar el desempeño en horizontes más largos, sería recomendable la implementación de estrategias como la incorporación de variables adicionales, la optimización

de hiperparámetros y el uso de modelos híbridos que combinen redes neuronales con otros enfoques de inteligencia artificial o estadísticos.

A pesar de estas limitaciones, los resultados proporcionan una base sólida para futuras investigaciones. La aplicación de esta tecnología puede optimizar la distribución de recursos y mejorar la toma de decisiones en problemas urbanos como la movilidad y el acceso al agua. Replicar este estudio en otras zonas y ciudades permitiría evaluar la generalización del modelo, mientras que la integración de enfoques híbridos podría mejorar su precisión y aplicabilidad en distintos contextos urbanos.

Índice	Métricas Estadísticas				
	R ²	MSE	MAE	MBE	RMSE
SPEI-3	0.649	0.280	0.406	0.080	0.525
SPEI-6	0.449	0.442	0.531	0.046	0.664
SPEI-12	-0.050	0.661	0.647	0.142	0.812

Tabla 1.- Resultados de las métricas estadísticas de los horizontes temporales de 3, 6 y 12 meses.

AGRADECIMIENTOS

Los autores agradecen al SMN y a CONAHCYT por el apoyo brindado. Asimismo, M.A.G.-O. agradece a la UACM por su apoyo mediante el proyecto UACM-CCyT-2023-IMP-05.

REFERENCIAS

[1] J.-L. Zhang, X.-M. Huang, y Y.-Z. Sun, “Multiscale spatiotemporal meteorological drought prediction: A deep learning approach”, *Adv. Clim. Change Res.*, vol. 15, núm. 2, pp. 211–221, abr. 2024, doi: 10.1016/j.accre.2024.04.003.

[2] Nate, C., “The Prolonged Drought in Australia: Causes, Impacts, and Mitigation Strategies”, *Int. J. Sci. Soc.*, vol. 5, núm. 4, pp. 723–733, oct. 2023, doi: 10.54783/ijssoc.v5i4.841.

[3] F. A. Prodhon, J. Zhang, S. S. Hasan, T. P. Pangali Sharma, y H. P. Mohana, “A review of machine learning methods for drought hazard monitoring and forecasting: Current research trends, challenges, and future research directions”, *Environ. Model. Softw.*, vol. 149, p. 105327, mar. 2022, doi: 10.1016/j.envsoft.2022.105327.

[4] L. Chaudhary, S. Sharma, T. Badal, y K. Chaurasia, “Prep_Seqnet: An Integrated ANN and Sequential Deep Learning Framework for Rainfall Prediction”, en *IGARSS 2024 - 2024 IEEE International Geoscience and Remote Sensing Symposium*, jul. 2024, pp. 5530–5533. doi: 10.1109/IGARSS53475.2024.10640592.

[5] Y. Sheikhi, S. M. Ashrafi, M. R. Nikoo, y A. Haghghi, “Enhancing daily rainfall prediction in urban areas: a comparative study of hybrid artificial intelligence models with optimization algorithms”, *Appl. Water Sci.*, vol. 13, núm. 12, p. 232, nov. 2023, doi: 10.1007/s13201-023-02036-8.

[6] W.-B. Jiang, “Implementing advanced techniques for urban mountain torrent surveillance and early warning using rainfall predictive analysis”, *Urban Clim.*, vol. 53, p. 101782, ene. 2024, doi: 10.1016/j.uclim.2023.101782.

[7] B. B. Gupta *et al.*, “Advance drought prediction through rainfall forecasting with hybrid deep learning model”, *Sci. Rep.*, vol. 14, núm. 1, p. 30459, dic. 2024, doi: 10.1038/s41598-024-80099-6.

[8] A. Shaikh, U. Patil, V. Shelar, y U. Pathak, “Advancing AI Models for Drought Forecasting, Challenges and Future Directions”, *Disaster Adv.*, vol. 17, núm. 12, pp. 58–71, oct. 2024, doi: 10.25303/1712da058071.

[9] P. J. Esquivel-Saenz, R. Ortiz-Gómez, M. Zavala, y R. S. Flowers-Cano, “Artificial Neural Networks for Drought Forecasting in the Central Region of the State of Zacatecas, Mexico”, *Climate*, vol. 12, núm. 9, Art. núm. 9, sep. 2024, doi: 10.3390/cli12090131.

[10] R. Magallanes-Quintanar, C. E. Galván-Tejada, J. I. Galván-Tejada, H. Gamboa-Rosales, S. de J. Méndez-Gallegos, y A. García-Domínguez, “Auto-Machine-Learning Models for Standardized Precipitation Index Prediction in North-Central Mexico”, *Climate*, vol. 12, núm. 7, Art. núm. 7, jul. 2024, doi: 10.3390/cli12070102.

[11] de M. Gobierno, “Información Estadística Climatológica”, smn.conagua.gob.mx. Consultado: el 18 de febrero de 2025. [En línea]. Disponible en: <https://smn.conagua.gob.mx/es/climatologia/informacion-climatologica/informacion-estadistica-climatologica>

[12] H. A. O. Sarlat, “Estrés hídrico en México bajo dos enfoques de huella de agua de escasez”, *Rev. Cent. Investig. Univ. Salle*, vol. 13, núm. 50, Art. núm. 50, 2018, doi: 10.26457/recein.v13i50.1738.

[13] B. Poudel, D. Dahal, M. Banjara, y A. Kalra, “Assessing Meteorological Drought Patterns and Forecasting Accuracy with SPI and SPEI Using Machine Learning Models”, *Forecasting*, vol. 6, núm. 4, Art. núm. 4, dic. 2024, doi: 10.3390/forecast6040051.

[14] M. Tiwari y M. P. Brahmabhatt, “Forecasting Drought Indices using Artificial Neural Network and M5 Model Tree Techniques in Middle Gujarat Region of India”, *J. Agric. Eng. India*, vol. 61, núm. 3, pp. 413–431, ago. 2024, doi: 10.52151/jae2024613.1856.

[15] H. A. Afan *et al.*, “LSTM Model Integrated Remote Sensing Data for Drought Prediction: A Study on Climate Change Impacts on Water Availability in the Arid Region”, *Water*, vol. 16, núm. 19, Art. núm. 19, ene. 2024, doi: 10.3390/w16192799.

[16] A. Parajuli, R. Parajuli, M. Banjara, A. Bhusal, D. Dahal, y A. Kalra, “Application of Machine Learning and Hydrological Models for Drought Evaluation in Ungauged Basins Using Satellite-Derived Precipitation Data”, *Climate*, vol. 12, núm. 11, Art. núm. 11, nov. 2024, doi: 10.3390/cli12110190.

[17] S. Barua, B. J. C. Perera, A. W. M. Ng, y D. Tran, “Drought forecasting using an aggregated drought index and artificial neural network”, *J. Water Clim. Change*, vol. 1, núm. 3, pp. 193–206, sep. 2010, doi: 10.2166/wcc.2010.000.

[18] S. Gao *et al.*, “Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation”, *J. Hydrol.*, vol. 589, p. 125188, oct. 2020, doi: 10.1016/j.jhydrol.2020.125188.

[19] D. C. Montgomery y G. C. Runger, *Applied statistics and probability for engineers*, vol. Seventh Edition. 2018.

[20] T. Hastie, R. Tibshirani, y J. Friedman, “Neural Networks”, en *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, T. Hastie, R. Tibshirani, y J. Friedman, Eds., New York, NY: Springer, 2009, pp. 389–416. doi: 10.1007/978-0-387-84858-7_11.