



UNIVERSIDAD AUTÓNOMA CHAPINGO

**POSGRADO EN INGENIERÍA AGRÍCOLA Y USO
INTEGRAL DEL AGUA**

**PRONÓSTICO DE SEQUÍAS USANDO REDES
NEURONALES ARTIFICIALES EN LA CUENCA
DEL RÍO SONORA, MÉXICO**

T E S I S

Que como requisito parcial para obtener el grado de

**DOCTOR EN INGENIERÍA AGRÍCOLA
Y USO INTEGRAL DEL AGUA**

Presenta:

M. I. CLAUDIO CÉSAR HERNÁNDEZ VÁSQUEZ

Bajo la supervisión de:

DRA. LAURA ALICIA IBÁÑEZ CASTILLO



Chapingo, Estado de México, julio de 2021



**PRONÓSTICO DE SEQUÍAS USANDO REDES NEURONALES ARTIFICIALES
EN LA CUENCA DEL RÍO SONORA, MÉXICO**

Tesis realizada por el **M.I. CLAUDIO CÉSAR HERNÁNDEZ VÁSQUEZ** bajo la supervisión del Comité Asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

DOCTOR EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA

DIRECTOR:



DRA. LAURA ALICIA IBÁÑEZ CASTILLO

ASESOR:



DR. RAMÓN ARTEAGA RAMÍREZ

ASESOR:



DR. ALEJANDRO ISMAEL MONTERROSO RIVAS

LECTOR EXTERNO



DRA. ROCIO CERVANTES OSORNIO

CONTENIDO

RESUMEN GENERAL	12
GENERAL ABSTRACT	13
CAPÍTULO 1. INTRODUCCIÓN GENERAL	14
CAPÍTULO 2. REVISIÓN DE LITERATURA	20
2.1. Definición de sequía	20
2.2. Clasificación de las sequías	20
2.2.1. Sequía meteorológica	22
2.2.2. Sequía agrícola	22
2.2.3. Sequía hidrológica	23
2.2.4. Sequía socioeconómica	23
2.3. Caracterización de las sequías	23
2.4. Índices de sequía	24
2.5. Pronóstico de sequías	26
2.6. Redes neuronales artificiales	27
2.6.1. Neurona biológica y neurona artificial	27
2.6.2. Función de activación	29
2.6.3. Célula de McCulloch-Pitts	31
2.6.4. Perceptrón simple	32
2.6.5. Perceptrón multicapa	32
2.6.6. Arquitectura	33
2.6.7. Aprendizaje	35
2.6.7.1. Entrenamiento	35
2.6.7.2. Validación	35

2.6.7.3.	Algoritmo Backpropagation	36
2.6.7.4.	Algoritmo Resilient Propagation	37
2.6.7.5.	Validación cruzada	38
2.7.	Investigaciones sobre la sequía en México	38
2.7.1.	Monitor de Sequía de México	42
2.8.	Literatura citada	43
CHAPTER 3. ANALYSIS OF METEOROLOGICAL DROUGHTS IN THE SONORA RIVER BASIN, MEXICO		51
3.1.	Abstract	52
3.2.	Resumen	53
3.3.	Introduction	54
3.4.	Materials and methods	56
3.4.1.	Description of the study area	56
3.4.2.	Climatic information used	57
3.4.3.	Estimation of missing data	57
3.4.4.	Regionalization of the study area	58
3.4.5.	Analysis of meteorological droughts	59
3.5.	Results and discussion	62
3.5.1.	Regionalization of the study area	62
3.5.2.	Analysis of meteorological droughts	65
3.6.	Conclusions	75
3.7.	References	76
CAPÍTULO 4. PRONÓSTICO DE SEQUÍAS METEOROLÓGICAS USANDO REDES NEURONALES ARTIFICIALES EN LA CUENCA DEL RÍO SONORA, MÉXICO		83

4.1.	Resumen	84
4.2.	Abstract	84
4.3.	Introducción	85
4.4.	Materiales y métodos	89
4.4.1.	Área de estudio	89
4.4.2.	Información climatológica	89
4.4.3.	Redes Neuronales Artificiales (RNA)	91
4.5.	Resultados y discusión	94
4.6.	Conclusiones	107
4.7.	Agradecimientos	108
4.8.	Literatura citada	108

LISTA DE TABLAS

CAPÍTULO 2. REVISIÓN DE LITERATURA

Tabla 1. Componentes principales de una neurona biológica y una neurona artificial.	29
---	----

CHAPTER 3. ANALYSIS OF METEOROLOGICAL DROUGHTS IN THE SONORA RIVER BASIN, MEXICO

Table I. Categories of drought intensity of the North American Drought Monitor.	61
Table II. Selected weather stations in the study area.	64
Table III. Descriptive statistics of the average time series of SPI and SPEI at different temporal scales by group of stations.	71
Table IV. Frequency of occurrence of drought events.	72

CAPÍTULO 4. PRONÓSTICO DE SEQUÍAS METEOROLÓGICAS USANDO REDES NEURONALES ARTIFICIALES EN LA CUENCA DEL RÍO SONORA, MÉXICO

Tabla 1. Estaciones climatológicas ubicadas en la zona de estudio.	91
Tabla 2. Modelos de redes neuronales artificiales para el pronóstico de sequías.	95
Tabla 3. Modelos óptimos de redes neuronales para el grupo 1.	96
Tabla 4. Modelos óptimos de redes neuronales para el grupo 2a.	98
Tabla 5. Modelos óptimos de redes neuronales para el grupo 2b.	100
Tabla 6. Modelos óptimos de redes neuronales para el grupo 3.	103
Tabla 7. Pronóstico de los índices SPI y SPEI de enero a marzo de 2014.	107

LISTA DE FIGURAS

CAPÍTULO 2. REVISIÓN DE LITERATURA

Figura 1. Evolución e impactos de la sequía (Valiente, 2001).	21
Figura 2. Estructura física de una neurona: a. Biológica y b. Artificial (Haykin, 1998).	28
Figura 3. Funciones de activación (Martín del Brío & Sanz Molina, 2001).	31
Figura 4. El perceptrón simple (Haykin, 1998; Isasi Viñuela & Galván León, 2004).	32
Figura 5. Estructura jerárquica de una red neuronal artificial (Martín del Brío & Sanz Molina, 2001).	34

CHAPTER 3. ANALYSIS OF METEOROLOGICAL DROUGHTS IN THE SONORA RIVER BASIN, MEXICO

Figure 1. Location of the study area and of weather stations.	57
Figure 2. Total variance explained by each principal component.	62
Figure 3. Groups of weather stations defined by PCA.	63
Figure 4. Mean annual isohyets and grouped weather stations.	65
Figure 5. SPI and SPEI series of mean values for group 1.	66
Figure 6. SPI and SPEI series of mean values for group 2a.	67
Figure 7. SPI and SPEI series of mean values for group 2b.	69
Figure 8. SPI and SPEI series of mean values for group 3.	70
Figure 9. Frequency of occurrence of drought events by group of stations.	73
Figure 10. Hydrological balance, for wet year (left) and dry year (right).	74

CAPÍTULO 4. PRONÓSTICO DE SEQUÍAS METEOROLÓGICAS USANDO REDES NEURONALES ARTIFICIALES EN LA CUENCA DEL RÍO SONORA, MÉXICO

Figura 1. Ubicación de la zona de estudio y estaciones climatológicas agrupadas por regiones homogéneas de precipitación.	90
Figura 2. Arquitectura de la red neuronal para SPEI 24 del grupo 1.	97
Figura 3. Entrenamiento y validación de la red neuronal para SPEI 24 del grupo 1.	97
Figura 4. Arquitectura de la red neuronal para SPI 3 del grupo 2a.	99
Figura 5. Entrenamiento y validación de la red neuronal para SPI 3 del grupo 2a.	99
Figura 6. Arquitectura de la red neuronal para SPEI 24 del grupo 2b.	101
Figura 7. Entrenamiento y validación de la red neuronal para SPEI 24 del grupo 2b.	101
Figura 8. Arquitectura de la red neuronal para SPEI 12 del grupo 3.	103
Figura 9. Entrenamiento y validación de la red neuronal para SPEI 12 del grupo 3.	104
Figura 10. SPEI observado y pronosticado del grupo 2b.	105

A mi familia
con todo mi amor

Agradecimientos

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) por brindarme los recursos económicos para la realización de los estudios de Doctorado.

A la Universidad Autónoma Chapingo (UACH) y al Posgrado de Ingeniería Agrícola y Uso Integral del Agua (IAUIA) por enriquecer mi formación académica, profesional y personal.

A la Dra. Laura Alicia Ibáñez Castillo por ayudarme a consolidar este proyecto de investigación, por toda la experiencia y conocimiento que me ha compartido.

Al Dr. Ramón Arteaga Ramírez por sus comentarios y observaciones tan asertivas y enriquecedoras para este proyecto.

Al Dr. Alejandro Ismael Monterroso Rivas por su apoyo incondicional, tiempo y dedicación para culminar este proyecto.

A la Dra. Rocío Cervantes Osornio por su tiempo, dedicación y experiencia puesta en la revisión de este proyecto.

Un agradecimiento especial al Dr. Jesús David Gómez Díaz[†] por encaminarme con sus consejos, conocimiento y amplia experiencia en el tema central de este proyecto de investigación.

A todos aquellos profesores y amigos que de manera desinteresada me brindaron su apoyo para la realización de este proyecto.

Datos biográficos



Datos personales

Nombre	Claudio César Hernández Vásquez
Fecha de nacimiento	12 de mayo de 1990
Lugar de nacimiento	San Pablo Huitzo, Oaxaca
No. de cartilla militar	D-0373496
CURP	HEVC900512HOCRSL03
Licenciatura	Ingeniería en Recursos Naturales Renovables
Cédula de licenciatura	08776027
Maestría	Maestría en Ingeniería Agrícola y Uso Integral del Agua
Cédula de maestría	10631145

Desarrollo académico

Bachillerato	Colegio de Bachilleres del Estado de Oaxaca, plantel 42
Licenciatura	Ingeniería en Recursos Naturales Renovables
Maestría	Maestría en Ingeniería Agrícola y Uso Integral del Agua

RESUMEN GENERAL

PRONÓSTICO DE SEQUÍAS METEOROLÓGICAS USANDO REDES NEURONALES ARTIFICIALES EN LA CUENCA DEL RÍO SONORA, MÉXICO

Claudio César Hernández-Vásquez¹, Laura Alicia Ibáñez-Castillo²

Las sequías son un fenómeno hidrometeorológico extremo que se caracteriza por la disminución de la precipitación en comparación con un valor promedio histórico de un periodo de tiempo determinado, su intensificación y prolongación provoca diversos impactos negativos a nivel ecológico, agrícola, hidrológico, económico y social. Por lo tanto, su monitoreo y pronóstico deben ser parte fundamental de la planeación de los recursos hídricos disponibles a nivel local, regional y nacional. En este estudio se calcularon los índices SPI y SPEI a escalas de 3, 6, 12 y 24 meses para el periodo de 1974 al 2013, se usaron 19 estaciones climatológicas ubicadas en la parte media y alta de la cuenca del río Sonora, México. Los valores de los índices de cada escala temporal se promediaron por grupo de estaciones, que previamente fueron definidos analizando su comportamiento pluvial medio anual y las características fisiográficas de la zona de estudio. Las series de valores medios se utilizaron, primero para caracterizar de manera temporal y espacial las sequías meteorológicas y después para evaluar la aplicabilidad de las redes neuronales artificiales para pronosticarlas. Los principales resultados del análisis de los índices indicaron tendencias al aumento en la intensidad y la frecuencia de las sequías y se identificaron eventos importantes en los años 1997, 1999, 2000 y 2011 a 2013. Al finalizar el pronóstico de los índices de sequía, los resultados mostraron que las habilidades predictivas de los modelos de redes neuronales artificiales fueron satisfactorias, con un coeficiente de determinación (R^2) promedio de 0.76 en la etapa final de validación. El SPEI reflejó un panorama más real de la disponibilidad de agua en la zona de estudio y su pronóstico obtuvo el mayor rendimiento estadístico, en comparación con el SPI.

Palabras clave: SPI, SPEI, regionalización de la precipitación, Perceptrón Multicapa (MLP), Validación cruzada

¹ Autor de tesis

² Director de tesis

GENERAL ABSTRACT

FORECAST OF METEOROLOGICAL DROUGHTS WITH ARTIFICIAL NEURAL NETWORKS IN THE SONORA RIVER BASIN, MEXICO

Claudio César Hernández-Vásquez¹, Laura Alicia Ibáñez-Castillo²

Droughts are an extreme hydrometeorological phenomenon characterized by a decrease in precipitation compared to a historical average value for a determined period. Their intensification and prolongation cause various negative impacts at an ecological, agricultural, hydrological, economic and social level. Therefore, their monitoring and forecasting should be a fundamental part of the strategy to preserve water resources at a local, regional and national level. In this study, SPI and SPEI index were calculated at scales of 3, 6, 12 and 24 months for the period from 1974 to 2013. Nineteen climatological stations located in the middle and upper part of the Sonora River basin, Mexico, were used. The index values of each time scale were averaged by group of stations, which were previously defined by analyzing their annual average rainfall behavior and the physiographic characteristics of the study area. The mean value series were used, first to characterize meteorological droughts in a temporal and spatial manner and then to evaluate the applicability of artificial neural networks to predict them. The main results of the index analysis indicated trends in increasing droughts intensity and frequency and identified major events in the years 1997, 1999, 2000 and 2011 to 2013 were identified. At the end of the forecasting of drought indices, the results showed that the predictive abilities of artificial neural network models were satisfactory, with an average coefficient of determination (R^2) of 0.76 in the final validation stage. The SPEI showed a more real picture of water availability in the study area and its prognosis obtained the highest statistical yield, compared to the SPI.

Keywords: SPI, SPEI, precipitation regionalization, Multilayer Perceptron (MLP), Cross validation

¹ Thesis author

² Thesis Advisor

CAPÍTULO 1. INTRODUCCIÓN GENERAL

Las sequías son un fenómeno meteorológico extremo que se caracteriza por la deficiencia de humedad de manera anormal y persistente que sus características extraordinarias provocan impactos considerables en los ecosistemas, la agricultura y la ganadería, afectando la vida de la población que vive en las zonas de riesgo (Castillo-Castillo et al., 2017; Eslamian et al., 2011; Hao & Singh, 2015). Se diferencia de la estación seca y de la aridez, porque la primera es un evento esperable y ordinario en el que la precipitación es menor a un umbral determinado y donde la vegetación al sufrir un estrés hídrico importante activa sus mecanismos de adaptación (Luengo-Ugidos et al., 2002). La aridez, en cambio, es un atributo que se asocia al clima de una región e implica niveles bajos de humedad disponible durante periodos significativos y es consecuencia de los procesos globales del flujo de energía (Aguirre-Rivera & Negrete-Sánchez, 2017).

Wilhite & Glantz (1985) establecieron cuatro tipos de sequías: meteorológica, agrícola, hidrológica y socioeconómica, las cuales pueden analizarse usando índices para expresar de forma numérica sus impactos (Valiente, 2001; Zarch et al., 2011). Estos cuatro enfoques han sido acogidos por la Organización Meteorológica Mundial (OMM) (Ponvert-Delisle & Dámaso, 2016) en su manual de indicadores e índices de sequía (OMM & Asociación Mundial para el Agua, 2016) y describe a los cincuenta de mayor uso en el mundo. Este organismo internacional recomienda considerar más de uno al estudiar las sequías, con el fin de examinar la sensibilidad y precisión de cada uno de ellos (Ortiz-Gómez et al., 2018). Entre los más usados y recomendados para la vigilancia de las sequías meteorológicas, se encuentran el SPI (*Standard Precipitation Index*) y el SPEI (*Standard Precipitation Evapotranspiration Index*). El primero de ellos, fue propuesto por McKee, Doesken, & John (1993) y se calcula con base en los registros mensuales de precipitación; por su parte, el SPEI fue planteado por Vicente-Serrano, Beguería, & López-Moreno (2010) basado en el SPI, pero como dato de entrada usa un balance hídrico mensual

que resulta de la diferencia entre la precipitación y la evapotranspiración potencial. Ambos índices permiten identificar condiciones de déficit y exceso de humedad a diferentes escalas temporales.

En la parte norte de México las sequías se presentan de manera recurrente como resultado de las bajas precipitaciones que son características de los climas áridos y semiáridos. Esta porción del país se ubica en el cinturón de los grandes desiertos del mundo, que son el resultado de la dinámica de la circulación general de la atmósfera y que produce dos zonas de alta presión atmosférica en latitudes cercanas a los 30° norte y sur (Aguirre-Rivera & Negrete-Sánchez, 2017). Por lo que, en el vigente Programa Nacional Hídrico 2020-2024 (CONAGUA, 2019) se plantea como tercer objetivo prioritario reducir la vulnerabilidad de la población ante las sequías, reconociendo que México es un país altamente vulnerable, principalmente en los estados del noroeste, centro y de la vertiente del Pacífico como Baja California, Sonora, Coahuila, Chihuahua, Zacatecas, Jalisco, Michoacán, Querétaro, Ciudad de México y Guerrero.

Por otra parte, los investigadores Mishra & Singh (2010) mencionan que, en los últimos años, las sequías han experimentado niveles de gravedad cada vez mayores y periodos más cortos de ocurrencia, haciendo que, además de identificar y monitorear las sequías sea necesario y prioritario su pronóstico para poder prevenir los efectos adversos que pudiera ocasionar. Existen diferentes herramientas para realizar esta tarea inmensa, es por eso que, Mishra & Singh (2011) resumen las ventajas, limitaciones y aplicaciones de diversas metodologías que van desde técnicas tradicionales como el modelado estadístico que se basa en regresiones de series de tiempo hasta las nuevas estrategias de inteligencia artificial como las redes neuronales que han demostrado capacidades satisfactorias para el modelado y pronóstico de los sistemas no lineales y series de tiempo no estacionarias como las sequías (Mishra & Desai, 2006). En México son pocos los estudios desarrollados en el ámbito del pronóstico de sequías empleando redes neuronales artificiales (RNA), sin embargo, podemos citar el trabajo de Ravelo et al.

(2014) quienes pronosticaron la intensidad de las sequías usando el SPI y el Índice de Severidad de Palmer en la región del Organismo de Cuenca “Pacífico Norte” y el trabajo de Villazón-Bustillos et al. (2016) quienes analizaron los patrones de precipitación para predecir la sequía en la región noroeste del estado de Chihuahua. En la cuenca del río Sonora, no existen antecedentes de estudios similares al propuesto y se considera de importancia porque dentro de sus límites se ubica la ciudad de Hermosillo, una de las importantes del estado y que ha sufrido un incremento poblacional importante durante los últimos años (Oertel et al., 2018), lo cual se ha visto reflejado en demandas más grandes de agua para uso urbano, industrial y agrícola, siendo este último el mayor usuario del agua disponible en la cuenca (Palma et al., 2015). En este contexto, se plantea como objetivo principal de este trabajo de investigación, evaluar la aplicabilidad de las RNA para pronosticar las sequias meteorológicas en la parte media y alta de la cuenca del río Sonora, México, usando los índices SPI y SPEI a escalas de 3, 6, 12 y 24 meses para el periodo de 1974 al 2013.

Para cumplir con el objetivo de esta investigación, el presente documento se organiza en tres capítulos:

En el *Capítulo 1 - Revisión de literatura* se describen los aspectos teóricos de las sequías, su clasificación y la manera de caracterizar sus impactos por medio de índices, se describen los elementos básicos para entender el pronóstico por medio de las redes neuronales artificiales, además se analizan los trabajos realizados en diferentes partes del país referentes al monitoreo y al pronóstico de las sequías.

En el *Capítulo 2 - Analysis of meteorological droughts in the Sonora river basin, Mexico* se caracterizan en intensidad, duración y frecuencia las sequías y se analiza la tendencia del fenómeno en cuatro regiones homogéneas de precipitación que se definieron de acuerdo con las características fisiográficas de la cuenca y con el análisis estadístico de los registros pluviales medios anuales de las estaciones climatológicas presentes en la zona.

En el *Capítulo 3 - Pronóstico de sequías meteorológicas usando redes neuronales artificiales en la cuenca del río Sonora, México* se evalúan diferentes arquitecturas de RNA multicapa para pronosticar las sequias y se propone el uso de la Validación cruzada como una técnica de control efectiva del sobreajuste de las redes neuronales.

Literatura citada

- Aguirre-Rivera, J. R., & Negrete-Sánchez, L. O. (2017). Aridez y sequía, conceptos climáticos relevantes para el altiplano potosino. *Universitarios Potosinos*, 14(216), 12–17.
- Castillo-Castillo, M., Ibáñez-Castillo, L. A., Valdés, J. B., Arteaga-Ramírez, R., & Vázquez-Peña, M. A. (2017). Análisis de sequías meteorológicas en la cuenca del río Fuerte, México. *Tecnología y Ciencias Del Agua*, VIII, 35–52.
- CONAGUA. (2019). Programa Nacional Hídrico 2020-2024. In Comisión Nacional del Agua (pp. 1–41).
- Eslamian, S., Ostad-Ali-Askari, K., Singh, V. P., Dalezios, N. R., Ghane, M., Yihdego, Y., & Matouq, M. (2011). A review of drought indices. *Environmental Reviews*, 19(NA), 333–349. <https://doi.org/10.1139/a11-013>
- Hao, Z., & Singh, V. P. (2015). Drought characterization from a multivariate perspective: A review. *Journal of Hydrology*, 527, 668–678. <https://doi.org/10.1016/j.jhydrol.2015.05.031>
- Luengo-Ugidos, M. Á., Ceballos-Barbancho, A., Martínez-Fernández, J., & Yuste-Yuste, C. (2002). Las rachas secas en el sector central de la cuenca del Duero. *Investigaciones Geográficas*, 27, 65–82.

- McKee, T. B., Doesken, N. J., & John, K. (1993). The relationship of drought frequency and duration to time scales. Eighth Conference on Applied Climatology, 17–22.
- Mishra, A.K., & Desai, V. R. (2006). Drought forecasting using feed-forward recursive neural network. *Ecological Modelling*, 198(1–2), 127–138. <https://doi.org/10.1016/j.ecolmodel.2006.04.017>
- Mishra, Ashok K., & Singh, V. P. (2010). A review of drought concepts. *Journal of Hydrology*, 391(1–2), 202–216. <https://doi.org/10.1016/j.jhydrol.2010.07.012>
- Mishra, Ashok K., & Singh, V. P. (2011). Drought modeling - A review. *Journal of Hydrology*, 403(1–2), 157–175. <https://doi.org/10.1016/j.jhydrol.2011.03.049>
- Oertel, M., Meza, F. J., Gironás, J., Scott, C. A., Rojas, F., & Pineda-Pablos, N. (2018). Drought propagation in semi-arid river basins in Latin America: Lessons from Mexico to the Southern Cone. *Water (Switzerland)*, 10(11), 1–21. <https://doi.org/10.3390/w10111564>
- OMM, O. M. M., & Asociación Mundial para el Agua. (2016). Manual de indicadores e índices de sequía. In Programa de gestión integrada de sequías, Serie 2 de herramientas y directrices para la gestión integrada de sequías.
- Ortiz-Gómez, R., Cardona-Díaz, J. C., Ortiz-Robles, F. A., & Alvarado-Medellín, P. (2018). Characterization of droughts by comparing three multiscale indices in Zacatecas, Mexico. *Tecnología y Ciencias Del Agua*, 9(3), 47–91. <https://doi.org/10.24850/j-tyca-2018-03-03>
- Palma, A., González, F., & Cruickshank, C. (2015). Managed aquifer recharge as a key element in Sonora River basin management, Mexico. *Journal of Hydrologic Engineering*, 20(3), 1–10. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001114](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001114)

- Ponvert-Delisle, B., & Dámaso, R. (2016). Algunas consideraciones sobre el comportamiento de la sequía agrícola en la agricultura de Cuba y el uso de imágenes por satélites en su evaluación. *Cultivos Tropicales*, 37(3), 22–41. <https://doi.org/10.13140/RG.2.1.4591.3843>
- Ravelo, A. C., Sanz Ramos, R., & Douriet Cárdenas, J. C. (2014). Detección, evaluación y pronóstico de las sequías en la región del Organismo de Cuenca Pacífico Norte, México. *Agriscientia*, 31(1), 11–24.
- Valiente, Ó. M. (2001). Sequía: definiciones, tipologías y métodos de cuantificación. *Investigaciones Geográficas*, 26, 59–80. <https://doi.org/10.14198/INGEO2001.26.06>
- Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. *Journal of Climate*, 23(7), 1696–1718. <https://doi.org/10.1175/2009JCLI2909.1>
- Villazón-Bustillos, D., Rubio-Arias, H. O., Ortega-Gutiérrez, J. A., Rentería-Villalobos, M., González-Gurrula, L. C., & Pinales-Munguía, A. (2016). Análisis en series de tiempo para el pronóstico de sequía en la región noroeste del estado de Chihuahua. *Ecosistemas y Recursos Agropecuarios*, 3(9), 307–315.
- Wilhite, D. A., & Glantz, M. H. (1985). Understanding the drought phenomenon: The role of definitions. *Water International*, 10(3), 111–120. <https://doi.org/10.1080/02508068508686328>
- Zarch, M. A. A., Malekinezhad, H., Mobin, M. H., Dastorani, M. T., & Kousari, M. R. (2011). Drought Monitoring by Reconnaissance Drought Index (RDI) in Iran. *Water Resources Management*, 25(13), 3485–3504. <https://doi.org/10.1007/s11269-011-9867-1>

CAPÍTULO 2. REVISIÓN DE LITERATURA

2.1. Definición de sequía

La sequía es un fenómeno hidrometeorológico tan complejo que presenta problemas de definición, pues resulta difícil darle un enfoque general que contemple todas sus características (Dracup et al., 1980; Serrano-Barrios et al., 2016), por lo tanto, cada una de sus conceptualizaciones dependerá exclusivamente del punto de vista del investigador y del objetivo que tenga para estudiarla. Por ejemplo, en el Glosario de términos usados en la Agrometeorología de la Organización Meteorológica Mundial (OMM, 1999) se definió a la sequía como un período seco anormal, que se prolonga lo suficiente para que el déficit de agua provoque un serio desbalance hidrológico que daña a los cultivos. Mientras que en los Términos de referencia de la Convención Internacional de Lucha contra la Desertificación (UNCCD, 1994), se definió a una sequía como el fenómeno meteorológico que se produce de manera natural cuando las lluvias son inferiores a los niveles normales registrados y que por lo tanto causan un agudo desequilibrio hídrico, perjudicando los sistemas de producción del suelo y la vegetación, alterando los procesos ecológicos e hidrológicos que se desarrollan dentro del sistema.

2.2. Clasificación de las sequías

Wilhite & Glantz (1985) analizaron más de 150 definiciones de sequía que incluían desde aquellas conceptuales de diccionarios o enciclopedias, hasta aquellas operacionales con un conocimiento más profundo de climatología y que ayudan a identificar el inicio, el fin y la intensidad de los eventos de sequía. De este análisis, definieron cuatro grupos de acuerdo con la disciplina científica desde la que eran descritas: meteorológica, agrícola, hidrológica y socioeconómica. Los primeros tres tratan de medir la sequía como un fenómeno físico y el cuarto como un balance de suministro y demanda. Estos enfoques fueron acogidos favorablemente por la

Organización Meteorológica Mundial (OMM) (Ponvert-Delisle Batista, 2016), que es el organismo internacional encargado de estudiar el estado y el comportamiento de la atmósfera de la Tierra.

Los cuatro tipos de sequía reflejan un proceso de evolución que está determinado por la variabilidad climática, por la duración del evento y por las interacciones entre el clima y la sociedad (Figura 1) (Valiente, 2001), en este sentido, son descritas en el orden de aparición y de sus consecuentes impactos.




Figura 1. Evolución e impactos de la sequía (Valiente, 2001).

2.2.1. Sequía meteorológica

Corresponde al déficit de la precipitación en comparación a una cantidad promedio en un tiempo determinado. Sus causas se deben principalmente a la variabilidad natural del clima, sin embargo, se reconoce que también es producto de una compleja interacción entre factores naturales y antropogénicos, dentro de los primeros podemos mencionar a los patrones de circulación atmosférica, el fenómeno de “El Niño” y la actividad solar, y dentro de los antropogénicos al uso de combustibles fósiles, la deforestación y los cambios del uso del suelo (Schubert et al., 2004; Sheffield et al., 2009).

La definición de sequía meteorológica varía dependiendo del lugar y del periodo de tiempo que se analice (mensual, estacional o anual), por lo que, una definición que es común en una región puede ser inapropiada en otra (Akhavan et al., 2010), debido a que las condiciones atmosféricas como la deficiencia de la precipitación es altamente variable de una región a otra. Ravelo et al. (2014) señalan que su intensificación y prolongación en el tiempo conlleva a la aparición de los otros tipos de sequía.

2.2.2. Sequía agrícola

Se presenta cuando las lluvias escasean y el agua en el suelo disminuye a tal grado de no satisfacer la demanda de las plantas, lo que provoca disminuciones considerables de la producción agrícola. Es difícil de establecer umbrales específicos para una sequía agrícola, incluso para una región en particular, debido a que la cantidad de agua demandada por las plantas depende de sus características biológicas, del clima, de la estación de crecimiento y de las propiedades físicas y biológicas del suelo, (Valiente, 2001).

2.2.3. Sequía hidrológica

Se refiere a la escasez de la precipitación que provoca una disminución continua en el suministro de agua superficial de arroyos, ríos y lagos provocando una merma gradual del agua subsuperficial y subterránea, hasta alcanzar niveles inferiores a las condiciones normales en un largo plazo. Este tipo de sequía es definida, generalmente, en escalas de cuenca hidrográfica o hidrológica y las actividades antropogénicas como el cambio de uso, la degradación de la tierra, la urbanización y la construcción de presas tendrían un impacto importante en la ocurrencia y la gravedad de este tipo de sequía. Para Linsley Jr et al. (1975) una sequía hidrológica es el periodo donde los caudales no satisfacen los usos que se establecieron bajo un determinado sistema de gestión de aguas.

2.2.4. Sequía socioeconómica

Se origina cuando el agua disponible disminuye por la escasez de las precipitaciones, hasta el punto de producir daños económicos y sociales. Le anteceden las sequías meteorológica, agrícola e hidrológica.

Existen diferentes definiciones de este tipo de sequía que conjugan la manera en que una sociedad y su economía se ven afectadas por la falta de agua, como la de Pita López (1995), quien la define como el déficit de agua que se da de forma inusual, provocando impactos negativos en la sociedad que la padece y que por lo tanto altera el desenvolvimiento normal de su vida colectiva.

2.3. Caracterización de las sequías

Burton et al. (1993) definieron siete parámetros para caracterizar a las sequías, separándolos en tres componentes: independiente, temporal y espacial.

a. Independiente

- I. Magnitud. Es la anomalía en porcentaje o la diferencia en valor absoluto de la precipitación o del caudal para el periodo en el que dura de la sequía.

b. Temporal

- I. Duración. Es el tiempo en años, meses o días consecutivos donde la precipitación o el caudal registrados son inferiores a las condiciones medias de un periodo establecido.
- II. Frecuencia. Es el número de eventos de sequía que se presentan en un periodo determinado. Puede medirse como la probabilidad empírica de que la precipitación o el caudal sean inferiores al promedio o del periodo de retorno del evento de sequía.
- III. Velocidad de implantación. Es el tiempo en el que el déficit de la precipitación o caudal alcanza su valor máximo.
- IV. Espaciamiento temporal. Es el tiempo alcanzado entre eventos de sequías, por lo que se proporciona la regularidad o aleatoriedad de una sequía.

c. Espacial

- I. Extensión. Es la superficie total en la que se registra un déficit hídrico.
- II. Dispersión espacial. Es la medida del grado de difusión o concentración de la anomalía de las precipitaciones o caudales.

2.4. Índices de sequía

Existe una amplia variedad de índices para caracterizar de forma numérica los impactos de la sequía (Valiente, 2001; Zarch et al., 2011). La Organización Meteorológica Mundial (OMM & Asociación Mundial para el Agua, 2016) en su

manual de indicadores e índices describe los 50 de mayor uso en las regiones más propensas a las sequías y señala que no hay ninguno que pueda atribuirse y ser aplicado a todos los tipos de sequía, regímenes climáticos y sectores afectados, razón por la cual, para poder analizar las sequías es conveniente considerar más de uno, a fin de examinar la sensibilidad y precisión de cada uno de ellos (Ortiz-Gómez et al., 2018).

Para identificar las principales características como la intensidad y la duración de las sequías meteorológicas se han desarrollado cuantiosos índices, sin embargo el de mayor uso y recomendado por la Organización Meteorológica Mundial (OMM) como punto de partida para la vigilancia de la sequía (OMM & Asociación Mundial para el Agua, 2016) es el SPI (*Standardized Precipitation Index*) que fue propuesto por McKee et al. (1993) y que utiliza para su cálculo, los registros históricos mensuales de la precipitación para establecer una probabilidad de ocurrencia con valores positivos y negativos que se correlacionan directamente con episodios de humedad o sequía. Al no tomar en cuenta la temperatura que es un componente importante en los procesos atmosféricos, en años recientes, se ha popularizado el uso del SPEI (*Standardized Precipitation Evapotranspiration Index*) que fue desarrollado por Vicente-Serrano et al. (2010) y que se basa en el SPI, con la diferencia que usa como dato de entrada un balance hídrico mensual resultado de la diferencia entre la precipitación y la evapotranspiración potencial. Ambos índices identifican las condiciones de déficit y exceso de humedad a diferentes escalas temporales. Los valores que corresponden a un período de 3 meses o inferior pueden ser útiles para la vigilancia básica de la sequía, los valores para un período de 6 meses o inferior son útiles para determinar los efectos de la sequía en la agricultura, y los valores para un período de 12 meses o más ayudan a analizar los efectos en la hidrología (OMM & Asociación Mundial para el Agua, 2016).

2.5. Pronóstico de sequías

El conocimiento anticipado de las características como la intensidad, la duración y la dispersión espacial de las sequías es importante para poder diseñar las medidas de mitigación, adaptación o prevención de sus efectos adversos (Castillo-Castillo et al., 2018). Un pronóstico preciso ayudaría a la gestión óptima de los recursos hídricos disponibles y puede llevarse a cabo mediante el uso de indicadores como la precipitación o partir de índices que la cuantifican y caracterizan como el SPI o el SPEI.

Mishra & Singh (2011) exponen las ventajas, limitaciones y aplicaciones de diversas metodologías para el pronóstico de las sequias como el análisis de regresión, las series de tiempo, los modelos de probabilidad, redes neuronales artificiales (RNA), modelos híbridos y minería de datos. Son varias las herramientas y metodologías que han sido sugeridas y probadas en diferentes regiones del mundo para el pronóstico de sequías, sin embargo, en los últimos años las RNA han demostrado que su capacidad de aprendizaje a través de ensayos repetidos las hace muy utilizables con diversas aplicaciones en todas las ciencias (Tkacz & Hu, 1999) y el campo de la hidrología no es la excepción, pues desde principios de los años noventa, han sido utilizadas exitosamente en el modelado del proceso lluvia-escorrentía, pronóstico de caudales, modelado de aguas subterráneas, calidad de agua, pronóstico de precipitaciones, series de tiempo hidrológicas y en la operación de presas (ASCE, 2000).

Dastorani & Afkhami (2011) exponen que las RNA tienen una habilidad sorprendente para capturar las relaciones no lineales entre variables y para relacionar los datos de entrada-salida, por su parte, Ravelo et al. (2014) añaden que debido a que las RNA debido a que aprenden a diferenciar patrones a partir de ejemplos dados, no es necesario establecer funciones de distribución o modelos a priori.

2.6. Redes neuronales artificiales

Las Redes Neuronales Artificiales (RNA) son modelos computacionales de procesamiento de información automático que imitan de manera simplificada, el complejo funcionamiento de las redes neuronales del cerebro humano. En general, tanto en las redes biológicas como en las artificiales existe un sistema de interconexión de “neuronas” que colabora en conjunto para producir un estímulo de salida.

2.6.1. Neurona biológica y neurona artificial

Una neurona biológica es una célula nerviosa que constituye el elemento primordial del sistema nervioso central, está formada por tres componentes principales: dendritas, cuerpo celular y axón. Las dendritas son ramificaciones de entrada de la célula que reciben una serie de impulsos electroquímicos que son llevados al interior de la neurona hasta el núcleo, donde son procesados para generar una respuesta que es propagada por el axón para llegar a las dendritas de otras células, a través la sinapsis (Figura 2a). La sinapsis es un potenciador o un inhibidor de la señal procedente de los axones (Isasi Viñuela & Galván León, 2004).

Una neurona artificial es una versión simplificada de una neurona biológica, pero puede establecerse fácilmente su equivalencia como se muestra en la Tabla 1. La neurona (k) genera una única salida (y_k), mediante el ingreso de un determinado número (n) de entradas ($x_1, x_2, x_3, \dots, x_n$) provenientes del exterior o bien, de la salida de otras neuronas. Los datos de entrada son ponderados por un número determinado de constantes adaptables llamadas pesos sinápticos ($w_1, w_2, w_3, \dots, w_n$), los cuales entrelazan a las neuronas, de manera que muestran la relevancia e intensidad de cada una de ellas. Una vez que las entradas han sido ponderadas, se suman en el núcleo de la neurona ($\sum$) para producir la entrada neta (u_k) que se verá afectada por el sesgo o bias (b_k) dependiendo si es positivo o negativo,

aumentándola o disminuyéndola de manera respectiva. Finalmente, la u_k es puesta a prueba por una función de activación (φ) que determina la magnitud de la y_k (Figura 2b) (Haykin, 1998). En términos matemáticos se puede describir el funcionamiento de una neurona (k), mediante las siguientes ecuaciones:

- a. El sumatorio, donde todas las entradas son ponderadas algebraicamente para producir la entrada neta.

$$u_k = \sum_{i=1}^n x_i w_{ki} = x_1 w_{k1} + x_2 w_{k2} + x_3 w_{k3} + \dots + x_n w_{kn} \quad (1)$$

- b. Bias, que tiene el efecto de aumentar o disminuir la entrada neta.

$$v_k = u_k + b_k \quad (2)$$

- c. La función de activación, donde la entrada neta es evaluada para producir la respuesta de salida.

$$y_k = \varphi(u_k + b_k) \quad (3)$$




Figura 2. Estructura física de una neurona: a. Biológica y b. Artificial (Haykin, 1998).

Tabla 1. Componentes principales de una neurona biológica y una neurona artificial.

Neurona biológica	Neurona artificial
Dendritas	Señales de entrada ($x_1, x_2, \dots, x_n$)
Sinapsis	Pesos sinápticos ($w_{k1}, w_{k2}, \dots, w_{kn}$)
Cuerpo celular y núcleo	Sumatoria (Σ) y función de activación (φ)
Axón	Salida (y_k)

2.6.2. Función de activación

La función de activación llamada también función de transferencia, es quien limita el rango de salida de una neurona como respuesta a la señal de entrada y puede ser lineal o no lineal. Esta función es seleccionada con el criterio del investigador y el problema a resolver, muchas veces por ensayo y error. En ocasiones es necesario escalar o transformar los datos de entrada para ajustarlos al rango de la función de activación (Llano et al., 2007). Entre las funciones más utilizadas, se encuentran:

- I. Función de paso, umbral o escalón. Comúnmente se utiliza en problemas de clasificación, donde la salida puede ser 0 o 1, dependiendo si el parámetro de la función es positivo o negativo (Figura 3a).

$$\varphi_1(v_k) = \begin{cases} 1 & \text{si } v_k \geq 0 \\ 0 & \text{si } v_k < 0 \end{cases} \quad (4)$$

- II. Función lineal. La salida es igual a su entrada como se puede observar en la Figura 3b.

$$\varphi_2(v_k) = v_k \quad (5)$$

- III. Función rampa. La salida está entre un rango de valores de -1 y 1, como se expresa en la siguiente ecuación y en la Figura 3c.

$$\varphi_3(v_k) = \begin{cases} -1 & \text{si } v_k \leq -1 \\ v_k & \text{si } -1 < v_k < 1 \\ 1 & \text{si } v_k \geq 1 \end{cases} \quad (6)$$

- IV. Función sigmoideal. Es la función más usada y recomendada en problemas de predicción. Los valores de entrada pueden oscilar entre menos y más infinito y la salida es restringida a valores de 0 y 1 (Figura 3d), de acuerdo con la expresión siguiente:

$$\varphi_4(v_k) = \frac{1}{1 + e^{-v_k}} \quad (7)$$

- V. Función tangente hiperbólica. La salida está entre un rango continuo de valores dentro de los intervalos de -1 y 1. En forma matemática se expresa de acuerdo con la ecuación 8 y gráficamente como se presenta en la Figura 3e.

$$\varphi_5(v_k) = \frac{1 - e^{-v_k}}{1 + e^{-v_k}} \quad (8)$$




Figura 3. Funciones de activación (Martín del Brío & Sanz Molina, 2001).

2.6.3. Célula de McCulloch-Pitts

Es la primera estructura considerada como neurona artificial, fue propuesta por McCulloch & Pitts (1943) quienes tomaron como objeto de estudio emular de manera simplificada las neuronas del cerebro y las consideraron como dispositivos con dos estados posibles: apagado (0) o encendido (1). Cada célula o neurona se caracteriza por $n + 1$ valores reales, con n pesos de las conexiones (w_i) correspondientes a las entradas (x_i), más un valor umbral (θ), que puede ser distinto para cada célula. La célula se activa al procesar la entrada y será 1, si la suma de las entradas multiplicadas por los pesos supera el umbral y 0 en caso contrario, como se expresa en la ecuación 9.

$$y(t + 1) = \begin{cases} 1, & \text{si } \sum_i x_i(t)w_i > \theta \\ 0, & \text{en caso contrario} \end{cases} \quad (9)$$

2.6.4. Perceptrón simple

El perceptrón simple es la forma menos compleja de los modelos de RNA y fue introducido por Rosenblatt (1958). Básicamente es un modelo unidireccional, en el que hay tantas neuronas de entrada como sean necesarias para resolver el problema en cuestión y una o más neuronas de salida (Figura 4). Cada neurona de entrada tiene conexiones con todas las neuronas de salida, y estas conexiones determinan las superficies de discriminación del sistema linealmente separable en clases, la función de activación es del tipo escalón para las neuronas de la capa de salida (Martín del Brío & Sanz Molina, 2001).




Figura 4. El perceptrón simple (Haykin, 1998; Isasi Viñuela & Galván León, 2004).

2.6.5. Perceptrón multicapa

El perceptrón multicapa (MLP, de su nombre en inglés *Multilayer Perceptron*) surgió como consecuencia de las limitaciones en la separabilidad no lineal del perceptrón simple, por lo que se considera una generalización de esta arquitectura. Isasi

Viñuela & Galván León (2004) mencionan que cualquier función continua dentro del conjunto de números reales (R^n) puede aproximarse mediante un MLP y que en la actualidad es el modelo de RNA más utilizado.

2.6.6. Arquitectura

Herrera Quispe et al. (2013), indican que la arquitectura de una red neuronal se refiere a su topología o estructura, esquema de interconexión y a la dirección del flujo de la información.

Las neuronas son agrupadas en estructuras que se denominan capas, que en conjunto constituyen una red neuronal (Figura 5). A la red neuronal con una sola capa se le conoce como unicapa y aquella con dos o más se le denomina multicapa, distinguiendo tres tipos de capas: de entrada, ocultas y de salida tal como se puede observar en la Figura 5c. La capa de entrada se compone por neuronas que reciben datos o señales procedentes del entorno para procesarlos. La capa oculta puede ser una o más, y es aquella que no tiene una conexión directa con el entorno y es donde se proporciona la no linealidad a la red. Finalmente, la capa de salida es aquella cuyas neuronas proporcionan la respuesta de la red neuronal.




Figura 5. Estructura jerárquica de una red neuronal artificial (Martín del Brío & Sanz Molina, 2001).

Las interconexiones entre las capas de una red pueden ser de forma total o local. De manera total, es cuando la salida de la neurona de una capa es la entrada de todas las neuronas de la capa que le sucede, mientras que, de manera local, la salida de una neurona es la entrada a sólo una región de las neuronas de la capa posterior.

Por la dirección del flujo de datos en una red neuronal existen las redes unidireccionales o de alimentación hacia adelante (*feedforward*) y las redes recurrentes (*feedback*). En las redes unidireccionales, la información circula en un único sentido, desde las neuronas de entrada hacia las de salida, en cambio, las redes recurrentes se caracterizan porque se crean bucles entre las neuronas, pudiendo aparecer conexiones entre la misma neurona, entre neuronas de una misma capa o entre neuronas de diferentes capas (Isasi Viñuela & Galván León, 2004).

2.6.7. Aprendizaje

2.6.7.1. Entrenamiento

Es la etapa en la que los parámetros libres de la red neuronal (pesos sinápticos y sesgos) se ajustan para adaptarse a un conjunto de datos o patrones y poder realizar correctamente una tarea deseada. Los valores de los pesos sinápticos se establecen como nulos o en forma aleatoria, en un inicio para después en el entrenamiento irse ajustando de manera iterativa hasta encontrar una respuesta aceptable (Haykin, 1998). Martín del Brío & Sanz Molina (2001) mencionan que el ajuste de estos parámetros se realiza mediante alguna regla o algoritmo de aprendizaje que va midiendo el rendimiento de la red neuronal, distinguiéndose dos tipos básicos: el supervisado y el no supervisado.

- Aprendizaje supervisado. Es aquel donde se presenta a la red un conjunto de patrones, junto con la salida deseada u objetivo, e iterativamente ésta ajusta sus pesos hasta que su salida tiende a ser la deseada, utilizando para ello información detallada del error que comete en cada paso.
- Aprendizaje no supervisado. Es aquel donde se presenta a la red una multitud de patrones sin adjuntar la respuesta que se desea, por lo tanto, la red, por medio de la regla de aprendizaje estima la función densidad de probabilidad, a partir de lo cual pueden reconocerse regularidades en el conjunto de entradas, extraer rasgos, o agrupar patrones según su similitud.

2.6.7.2. Validación

Es la etapa donde la red neuronal se somete a evaluación con datos que no fueron usados durante su entrenamiento. Si la red no arroja resultados razonables para este conjunto de datos de prueba, el entrenamiento aún no ha terminado. Esta fase es de suma importancia para asegurar que la red no se ha limitado a memorizar el

conjunto de datos de entrenamiento, sino que ha aprendido a generalizar, es decir, que tiene la capacidad de responder correctamente ante patrones nunca vistos (Martín del Brío & Sanz Molina, 2001).

2.6.7.3. Algoritmo Backpropagation

El algoritmo de aprendizaje básico para las redes neuronales artificiales del tipo MLP, es el de retropropagación de errores o también conocido como *Backpropagation* (BP) (Rumelhart et al., 1986). Básicamente se trata de un método de optimización por el descenso del gradiente de una función de error. Es del tipo de aprendizaje supervisado, donde la modificación de los parámetros libres de la red neuronal se realiza de manera que la salida que proporciona sea lo más próxima a la salida deseada, por lo tanto, el aprendizaje del MLP es equivalente a encontrar un mínimo de la función error, como se muestra en la ecuación 10.

$$\min_W E \quad (10)$$

Donde W hace referencia al conjunto de parámetros de la red y E a una función error que evalúa la diferencia entre las salidas proporcionadas por la red y las salidas deseadas. En la mayoría de los casos, la función error se define como:

$$E = \frac{1}{N} \sum_{n=1}^N e(n) \quad (11)$$

Siendo N el número de patrones, muestras o ejemplos y $e(n)$ el error cometido por la red para el patrón n , dado por:

$$e(n) = \frac{1}{2} \sum_{i=1}^{nC} (s_i(n) - y_i(n))^2 \quad (12)$$

Siendo $Y(n)=(y_1(n), \dots, y_{nC}(n))$ y $S(n)=(s_1(n), \dots, s_{nC}(n))$ los vectores de salida de la red y de salidas deseadas para el patrón n , de manera respectiva.

Por lo tanto, W es un mínimo de E , donde el error próximo a cero, implica que la salida de la red es próxima a la salida deseada, alcanzando así la regla de aprendizaje. En los MLP, la presencia de las funciones de activación no lineales hace que la respuesta de la red sea no lineal respecto a los parámetros ajustables, por lo que se vuelve un problema de minimización no lineal, requiriendo técnicas de optimización no lineales como el método del descenso del gradiente (Isasi Viñuela & Galván León, 2004).

El proceso de entrenamiento de una red con el algoritmo BP, se puede resumir en tres grandes fases:

- I. El cómputo hacia delante de los patrones de entrenamiento.
- II. El cálculo del error entre la salida de la red y la salida deseada.
- III. La propagación hacia atrás del error con el ajuste correspondiente de los pesos y umbrales del modelo, partiendo de la capa de salida.

2.6.7.4. Algoritmo Resilient Propagation

Para resolver algunos de los inconvenientes del BP se han planteado continuamente correcciones o variantes, la mayoría tratan de resolver el problema de lenta convergencia y algunas otras se centran en conseguir una mejor generalización del modelo. Es así como, como Riedmiller (1994) y Riedmiller & Braun, (1993) propusieron el método *Resilient Propagation* (RPROP) con y sin retroceso de peso de manera respectiva. Este método es considerado una versión superior de *Backpropagation* (BP), al resolver los problemas de convergencia lenta y el estancamiento de los pesos de la red alrededor de óptimos locales (Prasad et

al., 2013), además es reconocido como uno de los algoritmos más apropiados para entrenar las redes neuronales artificiales (Ortíz et al., 2007).

2.6.7.5. Validación cruzada

Velásquez et al. (2010) exponen que uno de los inconvenientes de las redes MLP es el sobreajuste u *overfitting*, que ocurre cuando la red neuronal ha aproximado correctamente los datos del aprendizaje, pero aún no responde de manera satisfactoria los patrones de validación. Una red I, idealmente, debe entrenarse hasta un punto óptimo, en el que el error de generalización sea mínimo y esto se puede alcanzar aplicando la técnica de validación cruzada o *Cross Validation* cuyo procedimiento consiste en entrenar y validar a la vez para detenerse en el punto óptimo, para lo cual, el conjunto total d datos disponibles se particiona en k subconjuntos aproximadamente del mismo tamaño, se realiza el entrenamiento con $k-1$ subconjuntos y se valida con el subconjunto restante. Este proceso se repite de manera iterativa con cada uno de los posibles subconjuntos de validación, como lo explican Martín del Brío & Sanz Molina (2001) y Velásquez H. (2013).

2.7. Investigaciones sobre la sequía en México

Ravelo et al. (2014) señalan que en diferentes partes de México han ocurrido severas y prolongadas sequías, lo ha encaminado a la creación de planes y programas para la gestión del recurso hídrico por parte de los diferentes niveles de gobierno y disminuir sus efectos negativos por medio de la prevención y mitigación. Asimismo, se han realizado estudios a nivel local o regional para detectar y caracterizar las sequías, como el de Campos-Aranda (2014), donde comparó el Déficit Probabilístico de Precipitación (PPD, por sus siglas en inglés), el Índice de Precipitación Estandarizada (SPI, por sus siglas en inglés) y el Índice de

Reconocimiento de Sequías (RDI, por sus siglas en inglés) para detectar y monitorear las sequías meteorológicas ocurridas de 1949 al 2012 en la estación climatológica de Fresnillo, Zacatecas. De igual manera, Campos-Aranda (2015) contrastó el rendimiento de estos índices en la estación de Zacatecas, Zacatecas, donde el PPD, SPI y RDI le permitió clasificar a las sequías según su severidad, usando los registros mensuales de precipitación de 1930 al 2012. Las conclusiones de ambos trabajos sugieren la aplicación conjunta de tales índices, para complementar y/o ratificar la clasificación de la sequía obtenida. Campos-Aranda (2017) con los datos de tres estaciones climatológicas de San Luis Potosí, comparó cuatro índices para la detección de las sequías: el Índice de Deciles Modificado (IDM), el Índice Estadístico Z (IEZ), el Índice Z de China (IZC) y el SPI, con base en sus resultados recomienda la aplicación conjunta del IZC y el SPI debido a que sus estimaciones eran similares y libres de anomalías. Campos Aranda (2018) describió de manera detallada el procedimiento operativo del Índice de Precipitación-Evapotranspiración Estandarizada (SPEI, por sus siglas en inglés) y lo aplicó a los registros históricos mensuales de precipitación y temperatura media de la estación Zacatecas, Zacatecas durante el periodo de 1930 al 2015 y formuló tres escenarios de cambio climático, donde encontró que las sequías leves y extremas aumentaban y recomendó el uso del SPEI en la caracterización de las sequías históricas y futuras, estas últimas sólo como de carácter orientativo.

A partir del SPI y SPEI Serrano-Barrios et al. (2016) y Castillo-Castillo et al. (2017) analizaron la variabilidad espacial y temporal de las sequías en la Cuenca Pacífico Norte de México entre 1961 y 2010 y en la cuenca del río Fuerte para el periodo de 1961 a 2012, respectivamente. Ambos trabajos coinciden en que el SPEI, es quien define de mejor manera los eventos de sequía en comparación con el SPI.

Por su parte, Esquivel Arriaga et al., (2017) analizaron de manera temporal las sequías en las cuencas Tepehuanes y Santiago, en el estado de Durango, para el periodo de 1961 al 2014 a partir del SPI, encontrando relación entre los años secos y los años clasificados como El Niño. Recientemente, Cerano Paredes et al. (2020)

analizaron el comportamiento de las sequías ocurridas de 1937 al 2016 en la cuenca del río Yaqui, mediante el SPI y su relación con el fenómeno climático El Niño en la modulación de su variabilidad. Magaña et al. (2021) estudiaron la sequía ocurrida entre 2011 y 2013, sus impactos en el suministro de agua en el Área Metropolitana de Monterrey y el riesgo al aumento de las sequías socioeconómicas en la región analizada.

En México la región norte del país ha sido la más estudiada respecto a las sequías, a pesar de ello, este fenómeno no es exclusivo de esta zona, por lo que también se han realizado otros estudios importantes. Ruiz-Alvarez et al. (2020) estudiaron las tendencias espaciotemporales mensuales y anuales de la precipitación de 1980 al 2017, ocurrida en 36 estaciones meteorológicas distribuidas en Aguascalientes, sus resultados mostraron tendencias al aumento de precipitación en el período de mayo a septiembre y tendencias a una disminución del agua disponible en los meses de enero, abril, octubre y diciembre. De la Barreda et al. (2020) realizaron un estudio en el sureste de México, específicamente en la península de Yucatán, donde exploraron la variabilidad temporal y espacial de la ocurrencia de sequías por medio del SPI, usaron técnicas estadísticas como el análisis de conglomerados y técnicas geoestadísticas como Kriging para generar mapas de precipitación y sequías para el período 1980-2011.

Es importante reconocer, que el estudio formal de las sequías en nuestro país ocurrió a raíz de la creación de la Comisión para la elaboración del Plan Nacional Hidráulico en 1975, cuando se realizaron los primeros trabajos para cuantificar el agua en las presas y se elaboraron los primeros mapas para identificar las zonas afectadas por las sequías con algún grado de intensidad (Domínguez, 2016). En el Programa Nacional Hídrico 2014-2018 (CONAGUA, 2014) se reconoce que México es un país altamente vulnerable a la sequía, por lo que plantea el Programa Nacional contra las Sequías (PRONACOSE) donde se promueve la elaboración de Programas de Medidas Preventivas y de Mitigación a la Sequía para minimizar los impactos ambientales, económicos y sociales que pudiera ocasionar. Y en el vigente

Programa Nacional Hídrico 2020-2024 (CONAGUA, 2019) se plantea como tercer objetivo prioritario reducir la vulnerabilidad de la población ante las sequías, principalmente en los estados del noroeste, centro y de la vertiente del Pacífico como Baja California, Sonora, Coahuila, Chihuahua, Zacatecas, Jalisco, Michoacán, Querétaro, Ciudad de México y Guerrero.

Aguirre Rivera & Negrete Sánchez (2017), plantean que, México se ubica geográficamente en uno de los dos grandes cinturones de alta presión atmosférica del planeta que hace que cerca del 52% del territorio nacional se catalogue como árido o semiárido, donde la poca precipitación pluvial hace que las sequías se presenten de manera recurrente. Lo que hace del monitoreo y del pronóstico, dos actividades fundamentales para la planeación de los recursos hídricos disponibles a nivel local, regional y nacional. La primera de ellas ha sido bastante explorada, dejando un poco de lado el pronóstico, sin embargo, se pueden citar algunos trabajos realizados, como el de Fuentes-Franco et al. (2018) donde propusieron un enfoque híbrido estadístico-dinámico como herramienta útil para mejorar los pronósticos de la precipitación estacional en México a partir de la temperatura de la superficie del mar predicha con el modelo ECMWF-S4, mismo que fue usado por Carrão et al. (2018) pero para pronosticar el SPI en América Latina. Castillo-Castillo et al. (2018) realizaron el pronóstico del SPI y SPEI durante el periodo 1961-2011, en 14 estaciones meteorológicas de la cuenca del río Fuerte mediante el algoritmo del filtro de Kalman discreto con un autorregresivo de segundo orden (DKF-AR2) y con un autorregresivo de segundo orden y entrada exógena (DKF-ARX), obteniendo mejores ajustes con DKF-AR2 para la parte alta de la cuenca y DKF-ARX para la parte media y baja.

En lo referente al pronóstico de las sequías usando redes neuronales artificiales podemos mencionar los trabajos desarrollados por Ravelo et al. (2014) quienes pronosticaron la intensidad de las sequías en la región del Organismo de Cuenca Pacífico Norte mediante el SPI y el Índice Severidad de sequía de Palmer (PDSI, por sus siglas en inglés) obteniendo coeficientes de Pearson iguales o superiores a

0.84 para pronósticos a 1 mes y a 0.60 para pronósticos a 3 meses, lo que se traduce en una buena correlación entre el índice de sequía calculado y el valor pronosticado mediante las redes neuronales y el trabajo de Villazón-Bustillos et al. (2016) donde utilizaron las redes neuronales NARX (*Nonlinear Autoregressive Exogenous*) para analizar los patrones de precipitación pluvial y poder predecir los próximos eventos de sequía en la región noroeste del estado de Chihuahua, obteniendo errores de predicción en la lluvia entre 2.35 y 12.16 mm utilizando modelos NARX, mientras que al usar modelos ARIMA los errores de predicción fueron mayores, oscilando entre 4.85 y 56.45 mm.

2.7.1. Monitor de Sequía de México

El Servicio Meteorológico Nacional (SMN), es la dependencia oficial de México que se encarga de generar la información meteorológica y climatológica a escala nacional y local de nuestro país. Dentro de sus objetivos, se encuentra la vigilancia continua de la atmósfera para identificar los fenómenos meteorológicos que pudieran afectar las distintas actividades económicas del país, por lo que es el encargado de detectar el estado actual y la evolución de las sequías. Para ello se apoya en el Monitor de Sequía en México (MSM) (CONAGUA-SMN, 2020) que forma parte del Monitor de Sequía de América del Norte (NADM, por sus siglas en inglés), resultado de la cooperación técnica entre expertos de las sequías en México, Estados Unidos y Canadá. La metodología del MSM se basa en la obtención e interpretación de siete diferentes índices, integrándolos mediante un sistema de información geográfica y por consenso se determinan las regiones afectadas de acuerdo con la escala de intensidades que es común en los tres países que va desde anormalmente seco (D0), sequía moderada (D1), sequía severa (D2), sequía extrema (D3) hasta una sequía excepcional (D4). El MSM no es un sistema de pronóstico, más bien describe la evolución de las sequías en magnitud y extensión espacial, en conjunto con sus impactos, principalmente en los sectores agropecuario e hídrico (Lobato-Sánchez, 2016).

2.8. Literatura citada

- Aguirre Rivera, J. R., & Negrete Sánchez, L. O. (2017). Aridez y sequía, conceptos climáticos relevantes para el altiplano potosino. *Universitarios Potosinos*, 14(216), 12–17.
- Akhavan, S., Abedi-koupai, J., Mousavi, S., Afyuni, M., Eslamian, S.-S., & Abbaspour, K. C. (2010). Application of SWAT model to investigate nitrate leaching in Hamadan–Bahar Watershed, Iran. *Agriculture, Ecosystems and Environment*, 139(4), 675–688. <https://doi.org/10.1016/j.agee.2010.10.015>
- ASCE. (2000). Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), 115–123.
- Burton, I., Kates, R. W., & White, G. F. (1993). *The environment as hazard* (T. G. Press, Ed.; 2nd ed.).
- Campos Aranda, D. F. (2018). Cuantificación con el SPEI de sequías históricas y bajo cambio climático probable en la estación climatológica Zacatecas, México. *Tecnología y Ciencias Del Agua*, IX(2), 210–233. <https://doi.org/10.24850/j-tyca-2018-02-09>
- Campos-Aranda, D. F. (2017). Cuantificación de sequías meteorológicas mensuales: cotejo de cuatro índices en tres localidades de San Luis Potosí, México. *Tecnología y Ciencias Del Agua*, VIII(3), 159–172.
- Campos-Aranda, Daniel F. (2014). Comparación de tres métodos estadísticos para detección y monitoreo de sequías meteorológicas. *Agrociencia*, 48(5), 463–476.
- Campos-Aranda, Daniel Francisco. (2015). Contraste de los índices DPP, SPI y RDI para clasificación de sequías, en la estación climatológica Zacatecas, México. *Tecnología y Ciencias Del Agua*, VI(1), 183–193.

- Carrão, H., Naumann, G., Dutra, E., Lavaysse, C., & Barbosa, P. (2018). Seasonal drought forecasting for Latin America using the ECMWF S4 forecast system. *Climate*, 6(2). <https://doi.org/10.3390/cli6020048>
- Castillo-Castillo, M., Ibáñez-Castillo, L. A., Valdés, J. B., Arteaga-Ramírez, R., & Vázquez-Peña, M. A. (2017). Análisis de sequías meteorológicas en la cuenca del río Fuerte, México. *Tecnología y Ciencias Del Agua*, VIII, 35–52.
- Castillo-Castillo, M., Ibáñez-Castillo, L. A., Valdés, J. B., Arteaga-Ramírez, R., & Vázquez-Peña, M. A. (2018). Pronóstico de sequías meteorológicas con Filtro de Kalman discreto en la cuenca del río Fuerte, México. *Agrociencia*, 52(7), 911–932.
- Cerano Paredes, J., Esquivel Arriaga, G., Sánchez Cohen, I., & Estrada Arrellano, J. R. (2020). Analysis of meteorological droughts in the Yaqui River Basin, Mexico and its relationship with ENSO. *Boletín de La Asociación de Geógrafos Españoles*, 86. <https://doi.org/10.21138/bage.2937>
- CONAGUA. (2014). *Programa Nacional Hídrico 2014-2018*.
- CONAGUA. (2019). *Programa Nacional Hídrico 2020-2024*.
- CONAGUA-SMN. (2020). *Monitor de Sequía de México (MSM)*. Comisión Nacional Del Agua, Sistema Meteorológico Nacional. <https://smn.conagua.gob.mx/es/climatologia/monitor-de-sequia/monitor-de-sequia-en-mexico>
- Dastorani, M. T., & Afkhami, H. (2011). Application of artificial neural networks on drought prediction in Yazd (Iran). *Desert*, 16, 39–48.
- de la Barrera, B., Metcalfe, S. E., & Boyd, D. S. (2020). Precipitation regionalization, anomalies and drought occurrence in the Yucatan Peninsula, Mexico.

International Journal of Climatology, 40(10), 4541–4555.
<https://doi.org/10.1002/joc.6474>

Domínguez, J. (2016). Revisión histórica de las sequías en México: de la explicación divina a la incorporación de la ciencia. *Tecnología y Ciencias Del Agua*, 7(5), 77–93. http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S2007-24222016000500077&lang=pt

Dracup, J. A., Lee, K. S., & Paulson, E. G. (1980). On the definition of droughts. *Water Resources Research*, 16(2), 297–302.
<https://doi.org/10.1029/WR016i002p00297>

Esquivel Arriaga, G., Bueno Hurtado, P., Velásquez Valle, M. A., Sánchez Cohen, I., & Constante García, V. (2017). Análisis de sequías mediante el Índice Estandarizado de Precipitación (SPI) en dos cuencas de la Sierra Madre Occidental. *AGROFAZ*, 17(2), 97–110.

Fuentes-Franco, R., Giorgi, F., Pavia, E. G., Graef, F., & Coppola, E. (2018). Seasonal precipitation forecast over Mexico based on a hybrid statistical–dynamical approach. *International Journal of Climatology*, 38(11), 4051–4065.
<https://doi.org/10.1002/joc.5550>

Haykin, S. (1998). *Neural networks: a comprehensive foundation* (2nd ed.). Prentice Hall.

Herrera Quispe, J., Yari, Y., Luque, E., & Túpac Valdivia, Y. J. (2013). Red Neuronal aplicada a la generación de caudales mensuales estocásticos. *XII Congreso de La Sociedad Peruana de Computación*, September, 41–48.
<https://doi.org/10.13140/2.1.4047.7762>

Isasi Viñuela, P., & Galván León, I. M. (2004). *Redes neuronales artificiales: Un enfoque práctico*. Pearson Educación, S.A.

- Linsley Jr, R. K., Kohler, M. A., & Paulhus, J. C. H. (1975). *Hydrology for engineers* (McGraw Hill, Ed.; 2da ed.).
- Llano, L., Hoyos, A., Arias, F., & Velásquez, J. (2007). Comparison of the Activation Functions Performance in Neural Networks Feedforward to approximate Data Functions with and without Noise. *Avances En Sistemas e Informática*, 4(2), 1–10.
- Lobato-Sánchez, R. (2016). El monitor de la sequía en México. *Tecnología y Ciencias Del Agua*, VII(5), 197–211.
- Magaña, V., Herrera, E., Ábrego-Góngora, C. J., & Ávalos, J. A. (2021). Socioeconomic drought in a mexican semi-arid city: Monterrey Metropolitan Area, a case study. *Frontiers in Water*, 3. <https://doi.org/10.3389/frwa.2021.579564>
- Martín del Brío, B., & Sanz Molina, A. (2001). *Redes neuronales y sistemas difusos*. Alfaomega.
- McCulloch, W. S., & Pitts, W. (1943). A logic calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115–133. <https://doi.org/10.1007/BF02478259>
- McKee, T. B., Doesken, N. J., & John, K. (1993). The relationship of drought frequency and duration to time scales. *Eighth Conference on Applied Climatology*, 17–22.
- Mishra, A. K., & Singh, V. P. (2011). Drought modeling - A review. *Journal of Hydrology*, 403(1–2), 157–175. <https://doi.org/10.1016/j.jhydrol.2011.03.049>
- OMM. (1999). *Glosario de términos usados en la Agrometeorología* (O. de las N. U. (ONU), Ed.). Organización Meteorológica Mundial.

- OMM, O. M. M., & Asociación Mundial para el Agua. (2016). Manual de indicadores e índices de sequía. In *Programa de gestión integrada de sequías, Serie 2 de herramientas y directrices para la gestión integrada de sequías*.
- Ortíz, D., Villa, F., & Velásquez, J. (2007). A Comparison between Evolutionary Strategies and RPROP for Estimating Neural Networks. *Avances En Sistemas e Informática*, 4(2), 135–144.
- Ortiz-Gómez, R., Cardona-Díaz, J. C., Ortiz-Robles, F. A., & Alvarado-Medellín, P. (2018). Characterization of droughts by comparing three multiscale indices in Zacatecas, Mexico. *Tecnología y Ciencias Del Agua*, 9(3), 47–91. <https://doi.org/10.24850/j-tyca-2018-03-03>
- Pita López, M. F. (1995). Las sequías: análisis y tratamiento. In J. de Andalucía (Ed.), *Consejo de Medio Ambiente*.
- Ponvert-Delisle Batista, D. R. (2016). Algunas consideraciones sobre el comportamiento de la sequía agrícola en la agricultura de Cuba y el uso de imágenes por satélites en su evaluación. *Cultivos Tropicales*, 37(3), 22–41. <https://doi.org/10.13140/RG.2.1.4591.3843>
- Prasad, N., Singh, R., & Lal, S. P. (2013). Comparison of back propagation and resilient propagation algorithm for spam classification. *Proceedings of International Conference on Computational Intelligence, Modelling and Simulation*, 29–34. <https://doi.org/10.1109/CIMSim.2013.14>
- Ravelo, A. C., Sanz Ramos, R., & Douriet Cárdenas, J. C. (2014). Detección, evaluación y pronóstico de las sequías en la región del Organismo de Cuenca Pacífico Norte, México. *Agriscientia*, 31(1), 11–24.
- Riedmiller, M. (1994). Advanced supervised learning in multi-layer perceptrons - from backpropagation to adaptive learning algorithms. *International Journal of Computer Standards and Interfaces*, 16, 265–278.

- Riedmiller, M., & Braun, H. (1993). A direct adaptive method for faster backpropagation learning: The RPROP algorithm. *Proceedings of the IEEE International Conference on Neural Networks (ICNN)*, 586–591. <https://doi.org/10.1109/icnn.1993.298623>
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>
- Ruiz-Alvarez, O., Singh, V. P., Enciso-Medina, J., Ontiveros-Capurata, R. E., & Corrales-Suastegui, A. (2020). Spatio-temporal trends of monthly and annual precipitation in Aguascalientes, Mexico. *Atmosphere*, 11(5). <https://doi.org/10.3390/ATMOS11050437>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323, 533–536. <https://doi.org/https://doi.org/10.1038/323533a0>
- Schubert, S. D., Suarez, M. J., Pegion, P. J., Koster, R. D., & Bacmeister, J. T. (2004). Causes of long-term drought in the U.S. Great Plains. *Journal of Climate*, 17(3), 485–503. [https://doi.org/10.1175/1520-0442\(2004\)017<0485:COLDIT>2.0.CO;2](https://doi.org/10.1175/1520-0442(2004)017<0485:COLDIT>2.0.CO;2)
- Serrano-Barrios, L., Vicente-Serrano, S. M., Flores-Magdaleno, H., Tijerina-Chávez, L., & Vázquez-Soto, D. (2016). Variabilidad espacio-temporal de las sequías en la cuenca pacífico norte de México (1961-2010). *Cuadernos de Investigación Geográfica*, 42(1), 185–204. <https://doi.org/10.18172/cig.2857>
- Sheffield, J., Andreadis, K. M., Wood, E. F., & Lettenmaier, D. P. (2009). Global and continental drought in the second half of the twentieth century: Severity-area-duration analysis and temporal variability of large-scale events. *Journal of Climate*, 22(8), 1962–1981. <https://doi.org/10.1175/2008JCLI2722.1>

- Tkacz, G., & Hu, S. (1999). *Forecasting GDP growth using artificial neural networks*. Bank of Canada.
- UNCCD. (1994). United Nations Convention to combat desertification in countries experiencing serious drought and/or desertification, particularly in Africa. In *United Nations Convention to Combat Desertification*. <https://documents-dds-ny.un.org/doc/UNDOC/GEN/G94/643/71/PDF/G9464371.pdf?OpenElement>
- Valiente, Ó. M. (2001). Sequía: definiciones, tipologías y métodos de cuantificación. *Investigaciones Geográficas*, 26, 59–80. <https://doi.org/10.14198/INGEO2001.26.06>
- Velásquez H., J. D., Fonnegra R., Y., & Villa G., F. A. (2013). Pronóstico de series de tiempo con redes neuronales regularizadas y validación cruzada. *Revista Vinculos*, 10(1), 267–279.
- Velásquez, J. D., Villa, F. A., & Souza, R. C. (2010). Time series forecasting using cascade correlation networks. *Ingeniería e Investigación*, 30(1), 157–162.
- Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. *Journal of Climate*, 23(7), 1696–1718. <https://doi.org/10.1175/2009JCLI2909.1>
- Villazón-Bustillos, D., Rubio-Arias, H. O., Ortega-Gutiérrez, J. A., Rentería-Villalobos, M., González-Gurrula, L. C., & Pinales-Munguía, A. (2016). Análisis en series de tiempo para el pronóstico de sequía en la región noroeste del estado de Chihuahua. *Ecosistemas y Recursos Agropecuarios*, 3(9), 307–315.
- Wilhite, D. A., & Glantz, M. H. (1985). Understanding the drought phenomenon: The role of definitions. *Water International*, 10(3), 111–120. <https://doi.org/10.1080/02508068508686328>

Zarch, M. A. A., Malekinezhad, H., Mobin, M. H., Dastorani, M. T., & Kousari, M. R. (2011). Drought monitoring by Reconnaissance Drought Index (RDI) in Iran. *Water Resources Management*, 25(13), 3485–3504. <https://doi.org/10.1007/s11269-011-9867-1>

CHAPTER 3. ANALYSIS OF METEOROLOGICAL DROUGHTS IN THE SONORA RIVER BASIN, MEXICO

ANÁLISIS DE SEQUÍAS METEOROLÓGICAS EN LA CUENCA DEL RÍO SONORA, MÉXICO

Claudio César Hernández-Vásquez¹, Laura Alicia Ibáñez-Castillo^{2*}, Jesús David
Gómez-Díaz^{3†}, Ramón Arteaga-Ramírez²

¹Doctorado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo, km. 38.5 carretera México-Texcoco, 56230, Chapingo, Estado de México, México.

²Departamento de Irrigación, Universidad Autónoma Chapingo, km. 38.5 carretera México-Texcoco, 56230, Chapingo, Estado de México, México.

^{3†}Departamento de Suelos, Universidad Autónoma Chapingo, km. 38.5 carretera México-Texcoco, 56230, Chapingo, Estado de México, México.

Corresponding author: libacas@gmail.com

3.1. Abstract

Drought is a complex natural hazard that has numerous negative effects on ecosystems, agriculture, and the economy. For this reason, it is difficult to provide a precise definition. Nevertheless, different conceptualizations converge in one common denominator: the deficit of precipitation with respect to an average historical value. Droughts in Mexico have been recurrent and persistent, resulting from complex interactions of the atmosphere with the oceans and the geographic and physiographic characteristic of the country. Several researchers have approached this phenomenon with indices to characterize it using features such as intensity, duration and frequency. In this study we analyze droughts in a spatiotemporal context at scales of 3, 6, 12 and 24 months with SPI and SPEI indices at 19 weather stations located in the middle and high parts of the Sonora River basin, Mexico, for the period 1974-2013. The regions were defined according to the patterns of mean annual rainfall behavior, applying statistical techniques and analyzing the physiographic characteristics of the study region. The general results indicate that drought intensity increased at the end of the time series analyzed, and important periods were identified in the years 1997, 1999, 2000 and 2011 to 2013. SPEI defined the drought periods and the increasing intensity trend better than SPI, demonstrating the importance of including variables such as evapotranspiration in the balance of available water.

Key words: SPI, SPEI, principal components analysis, regionalization of precipitation.

3.2. Resumen

Las sequías son un riesgo natural complejo y con numerosos efectos negativos en los ecosistemas, la agricultura y la economía por lo que es difícil proporcionar una definición precisa. Sin embargo, diferentes conceptualizaciones convergen en un denominador común: la deficiencia de precipitación con respecto a un valor promedio histórico. El problema de la sequía en México ha sido recurrente y persistente, resultado de complejas interacciones entre la atmósfera con los océanos y las características geográficas y fisiográficas del país. Diversos investigadores han abordado este fenómeno, empleando índices para caracterizarla usando algunos de sus parámetros como la intensidad, la duración y la frecuencia. En este estudio se analizaron las sequías meteorológicas de forma temporal y regional en escalas de 3, 6, 12 y 24 meses usando los índices SPI y SPEI en 19 estaciones climatológicas ubicadas en la parte media y alta de la cuenca del río Sonora, México para el periodo 1974-2013, las regiones fueron definidas de acuerdo con los patrones de comportamiento pluvial medio anual aplicando técnicas estadísticas y analizando las características fisiográficas de la zona de estudio. Los resultados generales indicaron que la intensidad de las sequías aumentó al final de las series de tiempo analizadas y se identificaron periodos importantes en los años 1997, 1999, 2000 y 2011 a 2013. El SPEI, a diferencia del SPI, definió de mejor manera los periodos de sequía y la tendencia al aumento de las intensidades, demostrando la importancia de incluir variables como la evapotranspiración dentro del balance de agua disponible.

Palabras clave: SPI, SPEI, análisis de componentes principales, regionalización de la precipitación

3.3. Introduction

Droughts were defined in the United Nations Convention to Combat Desertification (UNCCD, 1994) as a phenomenon that is produced naturally when rainfall is considerably lower than the normal recorded levels and, because of its extraordinary characteristic, has considerable impact at the ecological, economic and social levels. Climate change is producing higher temperatures, lower precipitation, and more droughts with higher intensity and duration (Castillo-Castillo et al., 2017)

Wilhite and Glantz (1985) established four types of droughts: meteorological, agricultural, hydrological and socioeconomic. The first three measure drought as a physical phenomenon, while the last it as a balance of supply and demand. These operational definitions that attempt to give objective criteria of specific applicability (Zargar et al., 2011) were favorably received by the World Meteorological Organization (Ponvert-Delisle and Dámaso, 2016) as well as by Esquivel-Arriaga et al. (2019), Khatiwada and Pandey (2019), Paredes et al.(2014) and Spinoni et al. (2019). Burton et al. (1993) defined seven parameters to characterize droughts: one independent (intensity), four referring to the temporal component (duration, frequency, rate of implantation and temporal spacing), and two referring to the spatial component (extension and dispersion). These parameters can be analyzed using indices to express impact numerically (Valiente, 2001; Zarch et al., 2011). The World Meteorological Organization (OMM and Asociación Mundial para el Agua, 2016) in their manual of drought indicators and indices, describes the 50 most-used indices worldwide and point out that none can be attributed or applied to all types of drought, climate regimes or affected sectors. For this reason, to analyze droughts, it is convenient to consider more than one index with the goal of examining the sensitivity and precision of each one (Ortiz-Gómez et al., 2018).

Numerous indices have been developed in recent years to identify characteristic of meteorological droughts. The most used is SPI (Standardized Precipitation Index) proposed by McKee et al. (1993). To calculate this index, monthly historical registers

of precipitation are used to establish a probability of occurrence with positive and negative values that correlate directly with episodes of humidity and drought. Only precipitation data are considered and not temperature, which is important for the water balance when processes of atmospheric warming are included and offers a panorama of evaporative demand. For this reason, Vicente-Serrano et al. (2010) proposed SPEI (Standardized Precipitation Evapotranspiration Index), which includes in its calculation a monthly climate water balance using the difference between precipitation and evapotranspiration as entry data. Both indices enable identification of conditions of deficit and excess humidity at different temporal scales. The corresponding values at a period of three month or less can be useful for basic drought monitoring, values for a period of 6 months or less to monitor effects on agriculture and values for a period of 12 months or more for hydrological effects (OMM and Asociación Mundial para el Agua, 2016).

Mishra and Singh (2010) mention that in recent years droughts have had higher peaks and severity levels superior to those registered in the past century, as well as shorter intervals of occurrence, signaling climate change. Droughts are insidious natural hazards that pose serious challenges, and their study, identification, and monitoring of their main characteristics have become integral parts of planning, preparation and mitigation at local, regional and even national scales (Lobato-Sánchez, 2016). CONAGUA (2013) identified a long hydrological drought in the Sonora Basin, from 1996 to 2009. Navarro and Moreno (2016) mentioned that the reservoirs “Abelardo Rodríguez” and “El Molinito” have been below the operational level between 1998 and 2014, levels that are not enough to supply water for the City of Hermosillo, Sonora.

Thus, the objective of this study was to analyze meteorological drought temporally and spatially in the middle and high regions of the Sonora River Basin, Mexico, for the period 1974 to 2013 using SPI and SPEI indices at scales of 3, 6, 12 and 24 months. The importance of this study resides in the detailed analysis of the drought situation described by CONAGUA (2013), highlighting the dramatic situation in

northern of Mexico over several years. The study responds to the recommendation of the Drought Monitor with SPI to develop a more detailed study by economic regions. The Sonora basin has experienced an increase in population in recent years and, thus, in water demand by the population and agriculture.

3.4. Materials and methods

3.4.1. Description of the study area

The Sonora River basin is located in the northeast-central part of the state of Sonora, bounded by the geographic coordinates 28°5'19" and 30°59'18" N and 109°52'8" and 111°37'52" W, and covering an area of 26,827 km². The current study includes only the middle and high parts of the basin, 21,220 km² (Fig. 1).

Mean annual precipitation varies from 300 to 600 mm; the highest values occur toward the northwestern part of the study area and to the south in areas of the Sierra Madre Occidental. Most of the rain falls in the summer, associated with the North American monsoon. However, in the winter there are also significant rainfall events, resulting from the impact of vortexes. Mean annual temperatures oscillate between 12 and 24 °C (CONABIO, 2020), the lowest values occur in the highest mountainous areas of the Cananea, Los Ajos and Aconchi mountain ranges. The municipalities included totally or partially in the study area are Aconchi, Arizpe, Bacoachi, Banámichi, Baviácora, Cananea, Carbó, Cucurpe, Hermosillo, Huépac, Imuris, Opodepe, Rayón, San Felipe de Jesús, San Miguel de Horcasitas and Ures, with a total population estimated at 973,800 by the INEGI (2015) inter-census survey.

3.4.2. Climatic information used

The series of monthly data on precipitation and maximum and minimum temperatures from a total of 29 stations were obtained from the network of weather stations of the Servicio Meteorológico Nacional (SMN, 2019) for the period 1974 to 2013, that is, 40 years of information. Of these stations, 19 are within the study area and 10 are nearby (Fig. 1).




Figure 1. Location of the study area and of weather stations.

3.4.3. Estimation of missing data

The series of data with climate information (precipitation and maximum and minimum temperatures) were not complete during the study period, and it was necessary to estimate the missing data. The method of Inverse Distance Weighting (IDW), or the US National Weather Service method, suggested by the World Meteorological Organization (OMM, 2011), was applied. According to Campos-Aranda (1998), the missing data of a station can be estimated based on observed data of the four

(preferably), three or two closest stations. Equations 1 and 2 present the formulas that are applicable for this method.

$$W_i = \frac{1}{d^2} \quad (13)$$

$$D_x = \frac{\sum_{i=1}^N (D_i \cdot W_i)}{\sum_{i=1}^N W_i} \quad (14)$$

where W_i is equal to the reciprocal of the square of the distance (d) given in km between each neighboring station with the known data (D_i) and the station missing the data (D_x).

3.4.4. Regionalization of the study area

For the spatial analysis of droughts, first, the climatological data were subjected to meticulous quality control in terms of their continuity, variability and magnitude. When the missing data were estimated with the IDW method to complete the series, the continuity criterion was satisfied. Variability and magnitude of the data were approached using three standard deviations above or below the mean value of the variable to enable identification of suspicious data, which were analyzed and compared with the registers of the neighboring stations and their validity determined or corrected, as suggested by Cuadrat et al. (2013) and Ravelo et al. (2014).

To determine the homogeneous regions of precipitation, the weather stations located in the study area were grouped in such a way that they would share similar patterns in the annual precipitation registers. To this end, two methodologies used complementarily were executed. The first was to generate the mean annual isohyets that were plotted manually on the digital elevation model, following the graphic method described by Gómez et al. (2008) where mean annual precipitation,

orographic characteristics and wind systems that impact the study area are contemplated. The second was the Principal Components Analysis (PCA) using the statistical software RStudio (2018) with the aim of representing the 19 included stations in a smaller number (Mallants and Feyen, 1990). Using linear combinations of the original data, the variables, factors, or principal components (PC) that explained successively most of the total variation were calculated (Urrutia and Lemus, 2010). Therefore, a matrix of 19 x 40 was generated, corresponding to the 19 weather stations and the 40 mean annual precipitation registers. Finally, with PC1 and PC2, a cluster analysis was performed with Euclidean distance as the method for generating the similarity matrix required for grouping the stations by Partitioning Around Medoids (PAM), also known simply as k-medoids. The advantages of the method are discussed by Estarellles et al. (1992) and Reynolds et al. (2006).

3.4.5. Analysis of meteorological droughts

There is a wide variety of indices and equations to quantify a drought and study it in three of its most important parameters: intensity, duration and frequency. In our study, SPI (Standardized Precipitation Index) and SPEI (Standardized Precipitation Evapotranspiration Index) were calculated at temporal scales of 3, 6, 12 and 24 months for the time series spanning from January 1974 to December 2013.

SPI was calculated following the methodology developed by McKee et al. (1993), using monthly historical registers of precipitation (P) to establish a probability of occurrence by fitting to gamma distribution. The fitted values are transformed to normal distribution.

Calculation of SPEI followed the methodology of Vicente-Serrano et al. (2010) where the temperature component is included to enable estimation of evapotranspiration (ETP). ETP is subtracted from precipitation, generating a climatic water balance (P-

ETP); this water balance is fit to a log logistic to later transform it to a normal standard distribution.

Evapotranspiration was calculated by the Hargreaves method modified by Droogers and Allen (2002), which contemplates average monthly temperature (T_{avg}), monthly temperature range (TD) computed as the difference between maximum and minimum temperatures, both in degrees Celsius, precipitation in mm (P) and radiation in $MJm^{-2}d^{-1}$ (RA). Expression (3) represents this reference evapotranspiration (ET_0).

$$ET_0 = 0.0013 \cdot 0.408 \cdot RA \cdot (T_{avg} + 17.0) \cdot (TD - 0.0123 \cdot P)^{0.76} \quad (15)$$

Radiation, RA , resulted from the equation proposed by the United Nations Food and Agriculture Organization (Allen et al., 2006).

The temporal scale used indicated the accumulated period of the entry variable (P for SPI and P -ETP for SPEI) taken into account for calculating the index. Thus, for the scale of three months, the accumulative of the entry variable of the month of interest and the two previous months is considered. For the scale of six months, the accumulative would be the month of interest plus the five previous months, and so forth.

The SPI and SPEI values, being standardized, can correlate with episodes of humidity and drought. The results are interpreted based on the categories used by the Drought Monitor of Mexico (DMM), whose principal objective is to describe drought evolution in terms of magnitude and spatial extension (Lobato-Sánchez, 2016) and forms part of the North American Drought Monitor (NADM) (Table I).

Table I. Categories of drought intensity of the North American Drought Monitor.

Range	Code	Category
$SI \geq 2.0$	W4	Exceptionally humid
$1.6 \leq SI < 2.0$	W3	Extremely humid
$1.3 \leq SI < 1.6$	W2	Severely humid
$0.8 \leq SI < 1.3$	W1	Moderately humid
$0.5 \leq SI < 0.8$	W0	Abnormally humid
$-0.5 < SI < 0.5$	N	Normal conditions
$-0.8 < SI \leq -0.5$	D0	Abnormally dry
$-1.3 < SI \leq -0.8$	D1	Moderately dry
$-1.6 < SI \leq -1.3$	D2	Severely dry
$-2.0 < SI \leq -1.6$	D3	Extremely dry
$SI \leq -2.0$	D4	Exceptionally dry

SI = Standardized index of drought (SPI, SPEI)

SPI and SPEI were calculated with the software SPEI.R for the RStudio program (2018) developed by Begueria and Vicente-Serrano (2017).

Once SPI and SPEI of each of the data series of the 19 weather stations are calculated and categorized, the results are aggregated by homogeneous precipitation regions (isohyets). With the series of aggregated values of the different temporal scales, droughts were identified, as well as their intensity, duration, frequency, and trend. Intensity was determined based on categories of drought intensity presented in Table I. Duration was estimated based on initial and final dates of those indices. Frequency was determined with the number of times that category was presented (Fig. 9). Trend was estimated by linear regression of SPI and SPEI and was plotted as the average slope of both tendencies (Fig. 5, 6, 7 and, 8).

3.5. Results and discussion

3.5.1. Regionalization of the study area

Weather stations were grouped according to reported mean annual precipitation: group 1 (300 to 400 mm), group 2 (400 to 500 mm) and group 3 (500 to 600 mm). Complementarily, the matrix of correlations between stations was constructed. The values obtained oscillated between 0.30 and 0.84, with a mean of 0.62 and a determinant of 2.22×10^{-11} . According to Urrutia and Lemus (2010), if a low determinant value different from zero is obtained, it indicates high intercorrelations between variables (stations), which is our case, and gives rise to factorial analysis of the principal components (PC). Figure 2 shows that the first two PC are the most important, explaining 35.28% and 14.80% of the total variability between stations, with respect to mean annual precipitation. This previous conclusion is based on Vicario et al. (2015), who conducted a study with series of monthly precipitation data from 15 stations belonging to the provinces of Córdoba, Santa Fe and Entre Ríos, Argentina for a period of 30 years. Their results revealed that PC1 and PC2 explained 75.1% of the observed variability between the stations and annual mean precipitation. Urrutia and Lemus (2010) found that the first two components explained 74% of the variance when they determined homogeneous patterns of temperature in six stations of the Department of Chocó, Colombia.




Figure 2. Total variance explained by each principal component.

Figure 3 shows the dispersion diagram from the cluster analysis of the stations obtained from PC1 and PC2 grouped according to the behavior patterns of average annual precipitation. The isohyets generated previously to partition the 19 stations into k=3 groups were taken as reference. In the same way, Vicario et al. (2015), who analyzed physical and pluviometric characteristics of 15 weather stations, generated three groups with similar behavior; their study differed in that they used the average chain-linking method.




Figure 3. Groups of weather stations defined by PCA.

By contrasting the results of the methodologies used for regionalizing the study area, we found that station 26271-Sinoquipe presented a discrepancy. With a register of average annual precipitation of 504.5 mm, it was placed in the polygon of isohyets of 500-600 mm (group 3). However, the PCA placed it in group 2, where we finally left it after analyzing its geographic location and the pluviometric characteristic along the series, in such a way that the limits of the corresponding isohyet were redefined.

Groups 1 and 3 consist of four stations each, and group 2 contained eleven. This last group was divided into two subgroups a and b, according to the physiography of the site. The stations of groups 1 and 2a are found within the physiographic province

of the Sonora plains, while group 2b and 3 are in the physiographic region of the Sierra Madre Occidental, with the particularity that group 2b is in the intermountain valleys that form the Aconchi, Cananea and Los Ajos mountain ranges.

The list of weather stations analyzed and the groups to which they belong are presented in Table II and Figure 4 locates them spatially within the generated isohyets.

Table II. Selected weather stations in the study area.

Station	Altitude	Latitude (N)	Longitude (W)	P (mm)	Tmax (°C)	Tmin (°C)	Est. Dat. (%)	Group	Isohyet (mm)
26139 Hermosillo II	221	29°05'56"	110°57'14"	363.5	32.2	17.7	0.3	1	300 – 400
26121 Ures	385	29°25'37"	110°23'31"	375.6	31.8	9.1	12.1		
26016 Carbo	464	29°41'03"	110°57'18"	374.6	31.2	13.0	4.9		
26074 Querobabi	661	30°03'02"	111°01'17"	394.0	31.2	11.3	12.1		
26032 El Orégano	279	29°13'48"	110°42'21"	410.6	33.8	14.1	6.9	2a	400 – 500
26274 Topahue	300	29°16'15"	110°38'09"	418.6	33.1	12.9	22.4		
26180 El Cajón	390	29°28'19"	110°44'09"	414.2	32.1	11.7	2.3		
26244 Rancho Viejo	450	29°07'37"	110°18'54"	458.6	31.1	12.4	28.1		
26199 Pueblo de Álamos	589	29°12'15"	110°08'25"	498.8	30.8	11.7	15.8		
26214 Huepac	644	29°54'46"	110°12'47"	496.5	30.1	9.7	19.7	2b	500 – 600
26008 Banamichi	675	30°00'12"	110°12'54"	459.7	30.7	13.3	1.7		
26271 Sinoquipe	740	30°09'20"	110°14'42"	504.5	30.5	11.6	39.8		
26005 Arizpe	836	30°20'08"	110°10'03"	474.5	29.4	10.0	31.9		
26007 Bacanuchi	1049	30°35'56"	110°14'18"	489.1	28.0	7.4	6.2		
26145 Bacoachi	1049	30°37'54"	109°58'12"	465.5	28.0	8.2	35.3	3	500 – 600
26198 Mazocahui	449	29°32'26"	110°07'09"	517.6	31.4	11.2	22.1		
26181 Rayón	560	29°42'38"	110°34'14"	500.5	30.6	11.8	7.7		
26241 Meresichic	712	30°01'50"	110°40'30"	521.8	28.5	11.0	38.9		
26025 Cucurpe	853	30°19'50"	110°42'21"	524.7	29.6	10.3	10.4		

P= Average annual precipitation, Tmax= Average maximum temperature,

Tmin= Average minimum temperature, Est. Dat. = Estimated data




Figure 4. Mean annual isohyets and grouped weather stations.

3.5.2. Analysis of meteorological droughts

The results of the analysis of meteorological droughts are presented by groups of stations (homogeneous precipitation regions) for which the SPI and SPEI historical series of the weather stations were averaged, and series of mean values for the different temporal scales used were obtained.

Figure 5 shows the series of average SPI and SPEI values for the stations of group 1 (Hermosillo, Ures, Carbo and Querobabi) where in 1982, 1997, 1999, 2010, 2011 and 2013 all the temporal scales reported droughts of some degree of intensity. The events evaluated as extreme occurred from August to December 1982 and January 2011 to July 2012, with intervals of exceptional drought in July 1982, March to May and September to October 2011, and in January to June 2012. CONAGUA (2013) reported periods of exceptional drought from 1999 to 2001 and severe drought events in 2004 to 2006 for the Carbo station.

In general, there are great similarities among the behavior of time series of drought indices; that is, drought occurrence is similar when they belong to the same group of weather stations. However, with SPI, on average, 28% of all the registers were identified with some degree of drought, while with SPEI, it was 30%. Moreover, the slope obtained from the time series fit to a linear regression model provided an estimation of the trend. In general, the trend is negative for all the temporal scales.




Figure 5. SPI and SPEI series of mean values for group 1.

The series of average SPI and SPEI values for group 2a, comprising El Orégano, Topahue, El Cajón, Rancho Viejo and Pueblo de Álamos, are presented in Figure 6. Exceptional drought events were identified in May 1999, March 2006 and June 2011,

and droughts of less intensity in 1980, 1987, 1997-2000, 2006, and 2011 in all the temporal scales. The longest drought, according to SPI and SPEI at the temporal scale of 24 months, occurred from September 1987 to June 1989 with moderate intensity. CONAGUA (2013) reported that, as of 1996, the hydrometric stations El Cajón and El Orégano registered a decrease in runoff, and the negative trend has continued in recent years.

The time behavior is similar for both indices. However, on average, we obtained 30% and 32% of all the registers with some degree of drought for SPI and SPEI, respectively. The latter index evaluates drought periods more rigorously at the end of the series, and the trend estimated by linear regressions was negative for all the time series.




Figure 6. SPI and SPEI series of mean values for group 2a.

Figure 7 presents the temporal series of mean values for the SPI and SPEI indices obtained from averaging the values of the same indices of the stations that are part of group 2b (Huepac, Banamichi, Sinoquipe, Arizpe, Bacanuchi and Bacoachi). At all the time scales, there was synchrony of drought events in 1980, 1997, 1999-2003 and 2011-2013, although of shorter duration than for groups 1 and 2a. In contrast, the longest events detected by both indices at a scale of 24 months occurred from July 1998 to October 2000 and from August 2010 to December 2013, with abnormal to severe intensities for both cases. Within the drought period October 2002 to January 2005, there was an extreme event from July 2003 to February 2004. CONAGUA (2013), however, in reports of the Alto Noroeste Basin Council, the northwestern part presents extreme droughts from March to November 2011, affecting the municipalities of Naco, Santa Cruz, Cananea, Bacoachi, Arizpe, Banámichi, Huépac, Aconchi, Baviacora, Ures, west Altar, Trincheras, Carbó and east Hermosillo. For this group, on average, a moisture deficit of 29% was registered by SPI and 32% by SPEI. The trend represented by the slope of the linear regression fit of the data is negative for all cases.




Figure 7. SPI and SPEI series of mean values for group 2b.

For group 3 (Mazocahui, Rayón, Meresichic and Cucurpe), Figure 8 shows the average SPI and SPEI time series. It can be observed that in 1975, 1976, 1997, 2000 and 2011-2013 there are drought events that synchronize in all the time scales. Of the longest events in this group, those that occurred from December 1974 to February 1978 detected in the SPI 12-month series is outstanding. Another outstanding event detected in the SPI 24-month series lasted from August 2010 to December 2013. Both cases had moderate intensities, and the 24-month SPEI categorized the event that occurred from July 1976 to June 1977 as extreme. Likewise, in December 2012, CONAGUA (2013) declared 11 municipalities of Sonora a disaster zone because of the severe droughts, among which was Cucurpe.

On average, of the different scales used, SPI detected 142 cases of drought, while SPEI found 138. The trend of the time series is negative, with a less steep slope as compared with the group of stations analyzed previously.




Figure 8. SPI and SPEI series of mean values for group 3.

Table III presents the descriptive statistics by groups of stations of the series of mean SPI and SPEI values at the different scales. The mean is near zero and the standard deviation near one (parameters of a normal standard distribution).

Table III. Descriptive statistics of the average time series of SPI and SPEI at different temporal scales by group of stations.

	SPI	Group					SPEI	Group			
		1	2a	2b	3			1	2a	2b	3
3	Drought (%)	27.20	26.99	28.03	29.08	3	Drought (%)	29.50	30.13	30.75	29.29
	Min.	-1.78	-2.04	-2.41	-3.34		Min.	-1.96	-1.93	-2.01	-1.68
	Mean	0.04	0.03	0.02	0.02		Mean	0.01	0.01	0.01	0.01
	S.D.	0.80	0.84	0.88	0.85		S.D.	0.82	0.88	0.88	0.79
6	Drought (%)	29.26	27.79	28.42	28.42	6	Drought (%)	29.47	31.37	33.26	27.16
	Min.	-2.13	-2.40	-2.46	-2.06		Min.	-1.97	-1.75	-1.89	-1.75
	Mean.	0.01	0.00	0.00	0.00		Mean	0.01	0.00	0.00	0.01
	S.D.	0.83	0.88	0.88	0.87		S.d.	0.82	0.88	0.88	0.79
12	Drought (%)	27.93	29.64	32.41	33.90	12	Drought (%)	31.34	32.20	32.62	32.84
	Min.	-2.04	-1.99	-1.97	-1.81		Min.	-1.75	-1.76	-1.66	-1.39
	Mean.	0.00	0.00	0.00	0.01		Mean.	0.00	0.00	0.00	0.00
	S.D.	0.84	0.85	0.84	0.87		S.D.	0.83	0.87	0.87	0.76
24	Drought (%)	29.32	34.14	29.10	29.54	24	Drought (%)	28.88	33.92	31.51	28.45
	Min.	-2.23	-1.52	-1.72	-1.89		Min.	-1.62	-1.60	-1.78	-1.25
	Mean.	0.00	0.00	0.00	0.00		Mean.	0.00	0.01	0.00	0.00
	S.D.	0.87	0.85	0.83	0.90		S.D.	0.85	0.86	0.87	0.71

Drought (%)= Drought in %, Min.= Minimum, S.D.= Standard deviation

In Table IV drought events are enumerated, according to the intensity detected by SPI and SPEI for each group of stations at 3, 6, 12 or 24 months, while in Figure 9 they are expressed in percentage by a frequency graph. In general, in groups 1, 2a and 2b moderate droughts predominate, while in group 3 most present abnormally dry conditions.

It should be mentioned that, on average, SPEI detected a higher number of drought events at the different scales, as well as a trend with a pronounced negative slope, which means an increase in intensity and demonstrates the relevance of including variables such as evapotranspiration in the study of droughts. However, SPI more

often characterized exceptional droughts. This behavior pattern was also reported by Serrano-Barrios et al. (2016) when they analyzed droughts in the north Pacific basin between 1961 and 2010. In a similar way, Campos-Aranda (2018), Castillo-Castillo et al. (2017) and Vicente-Serrano et al. (2012) concluded that temperature should not be omitted in the study of droughts.

Table IV. Frequency of occurrence of drought events.

Drought	Group	SPI 3	SPEI 3	SPI 6	SPEI 6	SPI 12	SPEI 12	SPI 24	SPEI 24
Exceptional	1	0	0	1	0	4	0	8	0
	2a	2	0	5	0	0	0	0	0
	2b	5	1	9	0	0	0	0	0
	3	1	0	1	0	0	0	0	0
Extreme	1	5	10	10	7	10	2	7	1
	2a	9	11	16	9	10	4	0	0
	2b	12	8	9	9	7	1	2	8
	3	9	3	16	1	5	0	17	0
Severe	1	16	13	15	13	12	14	23	23
	2a	23	22	14	28	21	20	10	24
	2b	16	20	16	22	18	24	15	16
	3	18	15	16	12	23	3	10	0
Moderate	1	48	52	53	62	61	76	46	63
	2a	42	64	55	61	55	77	59	64
	2b	53	65	60	70	60	79	63	61
	3	54	48	43	54	60	68	54	56
Abnormal	1	61	66	60	58	44	55	50	45
	2a	53	47	42	51	53	50	87	67
	2b	48	53	41	57	67	49	53	59
	3	57	74	59	62	71	83	54	74




Figure 9. Frequency of occurrence of drought events by group of stations.

In general, droughts were detected in 1997 and 2011. In 1999 and 2000 important events occurred in most of the study area, with the exception of groups 3 and 1 in the respective years. These results agree with those reported by Sthale et al. (2009), who stated that from 1994 to the early 21st century droughts have been more severe and sustained throughout Mexico. Proof of this are the results obtained by Castillo-Castillo et al. (2017), who found two periods of extreme drought from 1999 to 2004 and from 2011 to 2012 in the Fuerte River basin located in northwestern Mexico. CONAGUA (2013) reported droughts from 1999 to 2007, analyzing indices such as SPI, SPEI and that of Palmer. CONAGUA analyses detected the May-November 2011 droughts, occurring with some degree of intensity in practically 50% of the country's territory, affecting agriculture and livestock in the north of Mexico. It is worth mentioning that Eakin et al.(2007) described serious problems of lack of available water in the state of Sonora in the 1990s caused by a decrease in precipitation, and a severe drought was declared. Also, the reports of CONAGUA (2010) and Navarro and Moreno (2016) match our results.

Figure 10 shows how precipitation and evapotranspiration behave in a wet year and in a dry year. Notice how in all months of the dry year (2011) there is a negative water balance (P-ETP). But also notice that even in a wet year (1994), a negative balance is the trend. For this reason, we strongly recommend the use of the SPEI index to characterize drought in the Sonora basin.




Figure 10. Hydrological balance, for wet year (left) and dry year (right).

Finally, it is important to mention that the official Mexican agency responsible for following up the evolution of this phenomenon is the Servicio Meteorológico Nacional (SMN) supported by the Drought Monitor of Mexico (DMM), which is part of the North American Drought Monitor (NADM). DMM methodology is based on obtaining and interpreting diverse indices, among which is SPI. This index, according to Velasco et al. (2004), is one of the most used in North America. However, our study showed that SPEI was useful and has potential for detection of droughts. Also, while the SMN drought monitor gives a general view of the country, it is better to monitor drought specifically and in detail at the basin level to enable better planning to deal with droughts.

3.6. Conclusions

The values of SPI and SPEI at different temporal scales in the study area showed drought occurrence in several periods in 1997 and 2011 for all groups of stations throughout the Sonora basin. Droughts were identified in 1999 and 2000 in groups 2a and, 2b, while in 2012 and 2013 groups 1, 2b and 3 presented some moisture deficit.

The linear fit estimated by regression of the temporal series showed a negative trend throughout the study period, indicating a clear increase in the intensity and frequency of drought events in the study area. The negative trend occurred between 1997 and 2013, coinciding with results reported by different authors and institutions.

The frequency of drought in group 3 was lower, attributed to higher precipitation in these areas associated with the interaction of the mountain systems that force the ascent of winds from the Gulf of California, leading to increased condensation and precipitation development. In contrast, in group 2, located in the intermountain valleys where the winds descend and inhibit cloud formation, precipitation decreases and there is greater occurrence of exceptional droughts.

Calculation and interpretation of SPI and SPEI at different temporal scales enables convincing detection of the most important drought events of some intensity. However, because it uses a climate balance (P-ETP), SPEI includes water demand by the atmosphere and reflects a more real panorama of water availability in the study zone than SPI, which is based solely on precipitation data. We recommend the use of the SPEI over the SPI, because it explicitly considers temperature and evapotranspiration.

The results obtained in this work are relevant and helpful in future water planning and management for all uses. Future research in this topic and in this area should be directed to the seasonal forecast of droughts to enable advance preparation to reduce and mitigate their effects.

3.7. References

- Allen RG, Pereira LS, Raes D, Smith M. 2006. Evapotranspiración del cultivo: guías para la determinación de los requerimientos de agua de los cultivos. In Estudio FAO riego y drenaje (Vol. 298).
- Beguiría S, Vicente-Serrano SM. 2017. Calculation of Standardised Precipitation-Evapotranspiration index (1.7; Issue June). <http://sac.csic.es/spei>
- Burton I, Kates RW, White GF. 1993. The environment as hazard (T. G. Press, Ed.; 2nd ed.).
- Campos-Aranda DF. 1998. Procesos del ciclo hidrológico. Facultad de Ingeniería. Universidad de San Luis Potosí, 3rd ed.
- Campos-Aranda DF. 2018. Quantification with SPEI of historical Droughts and under probable climatic change in the climatological station Zacatecas, Mexico.

Tecnología y Ciencias del Agua, 9(2), 210–233. <https://doi.org/10.24850/j-tyca-2018-02-09>

Castillo-Castillo M, Ibáñez-Castillo LA, Valdés JB, Arteaga-Ramírez R, Vázquez-Peña MA. 2017. Análisis de sequías meteorológicas en la cuenca del río Fuerte, México. Tecnología y Ciencias del Agua, VIII(1), 35–52.

CONABIO. 2020. Portal de Geoinformación 2020, Climatología, Isotermas Medias Anuales. <http://www.conabio.gob.mx/informacion/gis>

CONAGUA. 2010. Estudio de escasez de agua en la cuenca del río Sonora. Organismo de Cuenca Noroeste, Hermosillo, Sonora. 58 p.

CONAGUA. 2013. Programa de Medidas Preventivas y de Mitigación a la Sequía (PMPMS) - Consejo de Cuenca Alto Noroeste. Comisión Nacional del Agua.

Cuadrat JM, Serrano R, Saz MA, Tejedor E, Prohom M, Cunillera J, Esteban P, Soubeyroux JM, Deaux N. 2013. Creación de una base de datos homogeneizada de temperaturas para los Pirineos (1950-2010). Geographica, 63–64, 63–74. https://doi.org/10.26754/ojs_geoph/geoph.201363-64854

Droogers P, Allen RG. 2002. Estimating reference evapotranspiration under inaccurate data conditions. Irrigation and Drainage Systems, 16(1), 33–45. <https://doi.org/10.1023/A:1015508322413>

Eakin H, Magaña V, Smith J, Moreno JL, Martínez JM, Landavazo O. 2007. A stakeholder driven process to reduce vulnerability to climate change in Hermosillo, Sonora, Mexico. Mitigation and Adaptation Strategies for Global Change, 12(5), 935–955. <https://doi.org/10.1007/s11027-007-9107-4>

Esquivel-Arriaga G, Cerano-Paredes J, Sánchez-Cohen I, Velásquez-Valle MA, Flores-López F, Bueno-Hurtado P. 2019. Temporal analysis of droughts (1922-

- 2016) in the upper Nazas River Basin using SPI and its relationship with ENSO. *Tecnología y Ciencias Del Agua*, 10(5), 126–151. <https://doi.org/10.24850/j-tyca-2019-05-05>
- Estarelles R, De la Fuente EI, Olmedo P. 1992. Aplicación y valoración de diferentes algoritmos no-jerárquicos en el análisis cluster y su representación gráfica. *Anuario de Psicología*, 55, 63–90.
- Gómez JD, Etchevers JD, Monterroso AI, Gay C, Campo J, Martínez M. 2008. Spatial estimation of mean temperature and precipitation in areas of scarce meteorological information. *Atmosfera*, 21(1), 35–56.
- INEGI. 2015. Encuesta Intercensal de Población y Vivienda 2015. Instituto Nacional de Estadística y Geografía. <http://cuentame.inegi.org.mx/monografias/informacion/son/poblacion>
- Khaliwada KR, Pandey VP. 2019. Characterization of hydro-meteorological drought in Nepal Himalaya: A case of Karnali River Basin. *Weather and Climate Extremes*, 26(November), 100239. <https://doi.org/10.1016/j.wace.2019.100239>
- Lobato-Sánchez R. 2016. El monitor de la sequía en México. *Tecnología y Ciencias del Agua*, 7(5), 197–211.
- Mallants D, Feyen J. 1990. Defining homogeneous precipitation regions by means of principal components analysis. *Journal of Applied Meteorology*, 29(9), 892–901. [https://doi.org/10.1175/1520-0450\(1990\)029<0892:DHPRBM>2.0.CO;2](https://doi.org/10.1175/1520-0450(1990)029<0892:DHPRBM>2.0.CO;2)
- McKee TB, Doesken NJ, John K. 1993. The relationship of drought frequency and duration to time scales. *Eighth Conference on Applied Climatology*, 17–22.
- Mishra AK, Singh VP. 2010. A review of drought concepts. *Journal of Hydrology*, 391(1–2), 202–216. <https://doi.org/10.1016/j.jhydrol.2010.07.012>

- Navarro NLA, Moreno VJL. 2016. Cambios en el paisaje arbolado en Hermosillo: escasez de agua y plantas nativas. *Región y Sociedad*, 28 (67), 79-120.
- OMM. 2011. Guía de prácticas climatológicas. Organización Meteorológica Mundial (Vol. 100). https://library.wmo.int/doc_num.php?explnum_id=10027
- OMM, Asociación Mundial para el Agua. 2016. Manual de indicadores e índices de sequía. Programa de gestión integrada de sequías, Serie 2 de herramientas y directrices para la gestión integrada de sequías.
- Ortiz-Gómez R, Cardona-Díaz JC, Ortiz-Robles FA, Alvarado-Medellín P. 2018. Characterization of droughts by comparing three multiscale indices in Zacatecas, Mexico. *Tecnología y Ciencias del Agua*, 9(3), 47–91. <https://doi.org/10.24850/j-tyca-2018-03-03>
- Paredes F, La Cruz F, Guevara E. 2014. Análisis regional de frecuencia de las sequías meteorológicas en la principal región cerealera de Venezuela. *Bioagro*, 26(1), 21–28.
- Ponvert-Delisle B, Dámaso R. 2016. Algunas consideraciones sobre el comportamiento de la sequía agrícola en la agricultura de Cuba y el uso de imágenes por satélites en su evaluación. *Cultivos Tropicales*, 37(3), 22–41. <https://doi.org/10.13140/RG.2.1.4591.3843>
- Ravelo AC, Sanz-Ramos R, Douriet Cárdenas JC. 2014. Detección, evaluación y pronóstico de las sequías en la región del Organismo de Cuenca Pacífico Norte, México. *Agriscientia*, 31(1), 11–24.
- Reynolds AP, Richards G, De la Iglesia B, Rayward-Smith VJ. 2006. Clustering rules: A comparison of partitioning and hierarchical clustering algorithms. *Journal of Mathematical Modelling and Algorithms*, 5(4), 475–504. <https://doi.org/10.1007/s10852-005-9022-1>

- RStudio Team. 2018. RStudio: Integrated Development Environment for R. RStudio, Inc. <http://www.rstudio.com/>
- Serrano-Barrios L, Vicente-Serrano SM, Flores-Magdaleno H, Tijerina-Chávez L, Vázquez-Soto D. 2016. Variabilidad espacio-temporal de las sequías en la cuenca pacífico norte de México (1961-2010). Cuadernos de Investigación Geográfica, 42(1), 185–204. <https://doi.org/10.18172/cig.2857>
- SMN. 2019. Red de Estaciones Climatológicas. Climatología mensual. México, DF. Servicio Meteorológico Nacional. <http://smn1.conagua.gob.mx/climatologia/Mensuales/>
- Spinoni J, Barbosa P, De Jager A, McCormick N, Naumann G, Vogt JV, Magni D, Masante D, Mazzeschi M. 2019. A new global database of meteorological drought events from 1951 to 2016. Journal of Hydrology: Regional Studies, 22(January), 100593. <https://doi.org/10.1016/j.ejrh.2019.100593>
- Sthale DW, Cook ER, Villanueva DJ, Fye FK, Burnette DJ, Griffin RD, Acuña SR, Seager R, Heim JRR. 2009. Early 21st- Century Drought in Mexico. EOS, Transactions, American Geophysical Union, 90(11), 89–100. <https://doi.org/10.1029/2009EO110001>
- UNCCD. 1994. United Nations Convention to combat desertification in countries experiencing serious drought and/or desertification, particularly in Africa. In United Nations Convention to Combat Desertification. <https://documents-dds-ny.un.org/doc/UNDOC/GEN/G94/643/71/PDF/G9464371.pdf?OpenElement>
- Urrutia JA, Lemus RP. 2010. Componentes principales en la determinación de estaciones con patrones homogéneos de temperatura en El Chocó. Scientia et Technica, 2(45), 257–262.

- Valiente OM. 2001. Sequía: definiciones, tipologías y métodos de cuantificación. *Investigaciones Geográficas*, 26, 59–80. <https://doi.org/10.14198/INGEO2001.26.06>
- Velasco I, Aparicio J, Valdés JB, Velázquez J, Kim T. 2004. Evaluación de índices de sequía en las cuencas de afluentes del río Bravo/Grande. *Ingeniería Hidráulica En México*, XIX(3), 37–53.
- Vicario L, García CM, Teich I, Bertoni JC, Ravelo A, Rodríguez A. 2015. Caracterización de las sequías meteorológicas en la región central de la Argentina. *Tecnología y Ciencias Del Agua*, 6(1), 153–165.
- Vicente-Serrano SM, Beguería S, Lorenzo-Lacruz J, Camarero JJ, López-Moreno JI, Azorín-Molina C, Revuelto J, Morán-Tejeda E, Sánchez-Lorenzo A. 2012. Análisis comparativo de diferentes índices de sequía para aplicaciones ecológicas, agrícolas e hidrológicas. *Octavo Congreso Internacional de La Asociación Española de Climatología: Cambio Climático, Extremos e Impactos*, 679–689. https://repositorio.aemet.es/bitstream/20.500.11765/8332/1/0066_VIII-2012-SM_VICENTE.pdf
- Vicente-Serrano SM, Beguería S, López-Moreno JI. 2010. A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. *Journal of Climate*, 23(7), 1696–1718. <https://doi.org/10.1175/2009JCLI2909.1>
- Wilhite DA, Glantz MH. 1985. Understanding the drought phenomenon: The role of definitions. *Water International*, 10(3), 111–120.
- Zarch MAA, Malekinezhad H, Mobin MH, Dastorani MT, Kousari MR. 2011. Drought Monitoring by Reconnaissance Drought Index (RDI) in Iran. *Water Resources Management*, 25(13), 3485–3504. <https://doi.org/10.1007/s11269-011-9867-1>

Zargar A, Sadiq R, Naser B, Khan FI. 2011. A review of drought indices. *Environmental Reviews*, 19(1), 333–349. <https://doi.org/10.1139/a11-013>

CAPÍTULO 4. PRONÓSTICO DE SEQUÍAS METEOROLÓGICAS USANDO REDES NEURONALES ARTIFICIALES EN LA CUENCA DEL RÍO SONORA, MÉXICO

FORECAST OF METEOROLOGICAL DROUGHTS WITH NEURAL NETWORKS IN THE SONORA RIVER BASIN, MEXICO

Claudio César Hernández-Vásquez^{1*}, Laura Alicia Ibáñez-Castillo², Ramón Arteaga-Ramírez², Alejandro Ismael Monterroso-Rivas³, Rocío Cervantes-Osornio⁴

¹Doctorado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo, km. 38.5 carretera México-Texcoco, 56230, Chapingo, Estado de México, México.

²Departamento de Irrigación, Universidad Autónoma Chapingo, km. 38.5 carretera México-Texcoco, 56230, Chapingo, Estado de México, México.

³Departamento de Suelos, Universidad Autónoma Chapingo, km. 38.5 carretera México-Texcoco, 56230, Chapingo, Estado de México, México.

⁴Campo Experimental Valle de México-INIFAP, km 13.5 carretera Los Reyes- Texcoco, 56230, Coatlinchán, Estado de México, México.

Autor para correspondencia: claudiohdezvqz@gmail.com

Resumen

Las sequías son un fenómeno hidrometeorológico extremo que se caracteriza por la deficiencia de humedad de manera anormal y persistente. En los últimos años este fenómeno se ha presentado con mayor frecuencia y con niveles de gravedad cada vez más intensos lo que ha provocado numerosos impactos negativos en los sistemas ecológicos, agrícolas, ganaderos y sociales. Por lo tanto, su monitoreo y pronóstico deben ser parte integral de la planeación, preparación y mitigación de sus efectos adversos a nivel local, regional e incluso nacional. En México los estudios se han enfocado mayoritariamente en la caracterización y análisis de los eventos de sequía, por lo que el objetivo de este estudio fue evaluar la aplicabilidad de las redes neuronales artificiales (RNA) para pronosticar las sequías meteorológicas en la parte media y alta de la cuenca del río Sonora, México. Para ello se utilizaron los índices SPI y SPEI a escalas temporales de 3, 6, 12 y 24 meses, para el periodo de 1974 al 2013. De manera general, los resultados mostraron que las habilidades predictivas de los modelos de RNA fueron satisfactorias, con un coeficiente de determinación (R^2) promedio de 0.76 en la etapa final de validación de los modelos. Se observó que el rendimiento estadístico de los modelos para el pronóstico del SPEI fue superior al SPI y que este aumentaba conforme la escala temporal era mayor, probablemente debido a que a corto plazo existe mayor variabilidad de las condiciones climáticas.

Palabras clave: SPI, SPEI, Perceptrón Multicapa (MLP), validación cruzada, propagación resiliente (RPROP)

4.2. Abstract

Droughts are hydrometeorological hazards that are characterized by an abnormal and persistent humidity deficit. In the last years, this hazard it has been present more frequently and with more severity levels, producing negative impacts in the

ecosystem, agriculture, livestock, and, in society. Therefore, its monitoring and forecast, must be part of an integral planning, preparation, and mitigation of its adverse effects in local, regional, and national levels. In Mexico, most of the drought studies are focused in characterization and analysis. Thus, in this research, we evaluated the application of artificial neural networks (ANN) to forecast the meteorological droughts in the medium and high parts of Sonora river watershed. SPI and SPEI index were used, in scales of 3, 6, 12, and, 24 months, for the 1974 to 2013 period of years.

Forecast results showed that ANN have a satisfactory level of prediction, with an average determination coefficient, R^2 , in the validation phase, of 0.76. It was observed that the statistical efficiency of SPEI was better than that of SPI, and that this efficiency increased with the longer temporal scale; maybe because in a short term, climate variability is greater.

Keywords: SPI, SPEI, multilayer perceptron (MLP), Cross Validation, resilient propagation (RPROP)

4.3. Introducción

Las sequías se clasifican en: meteorológica, agrícola, hidrológica y socioeconómica (Wilhite & Glantz, 1985), la primera de ellas se distingue por una disminución de la precipitación en comparación con la media histórica de un periodo de tiempo determinado, su intensificación y prolongación lleva a la aparición de los otros tipos de sequía (Ravelo et al., 2014). Para su estudio y monitoreo se han empleado índices como una herramienta para evaluar sus principales características como la intensidad y la duración; entre los más usados se encuentran el SPI (*Standard Precipitation Index*) y el SPEI (*Standard Precipitation Evapotranspiration Index*). El primero de ellos, fue propuesto por McKee et al. (1993) y es recomendado por la Organización Meteorológica Mundial (OMM) como punto de partida para la

vigilancia de la sequía (OMM & Asociación Mundial para el Agua, 2016), se calcula con base en los registros mensuales de precipitación; en cambio, el SPEI fue propuesto por Vicente-Serrano et al. (2010) basado en el SPI y como dato de entrada usa un balance hídrico mensual que resulta de restar la evapotranspiración potencial a la precipitación. Ambos índices presentan valores positivos y negativos que se correlacionan directamente con eventos de humedad o sequía y al ser de naturaleza probabilística describen características ideales para pronóstico y análisis de riesgos (Anshuka et al., 2019), lo cual es importante para la toma de decisiones y acciones oportunas para evitar, reducir o mitigar los efectos adversos de este fenómeno extremo mediante la información anticipada de su intensidad, duración y dispersión espacial (Castillo-Castillo et al., 2018).

Mishra & Singh (2011) exponen las ventajas, limitaciones y aplicaciones de diversas metodologías para el pronóstico de sequías, entre ellas describen a las redes neuronales artificiales (RNA), una idea que fue propuesta por McCulloch & Pitts (1943) hace más de setenta años y que ha venido experimentando un gran resurgimiento desde inicios de los años noventa, debido al desarrollo de algoritmos más sofisticados y la aparición de potentes herramientas computacionales. En hidrología, por ejemplo, se han utilizado con éxito en el pronóstico de precipitaciones, en el modelado del proceso lluvia-escorrentía, en el pronóstico de caudales, en la modelación de aguas subterráneas (ASCE, 2000) y en lo referente al pronóstico de sequías Achour et al. (2020), mencionan que los modelos de inteligencia artificial como lo son las redes neuronales podrían arrojar mejores resultados que las técnicas convencionales como las cadenas de Markov, métodos de regresión y modelos estocásticos lineales autorregresivos de media móvil integrada (ARIMA) y de media móvil integrada autorregresiva estacional (SARIMA).

Las RNA son sistemas de procesamiento de información inspirados en las redes neuronales biológicas; tienen la capacidad de aprender, recordar y generalizar a partir de ejemplos o patrones de entrenamiento, tal y como lo hace el cerebro humano (ASCE, 2000). Son consideradas una herramienta eficaz para modelar

procesos no lineales, utilizan técnicas de regresión no paramétrica para relacionar las entradas y las salidas del sistema sin necesidad de entender el proceso físico implicado (Djrbouai & Souag-Gamane, 2016). De manera general, el procesamiento de la información en las RNA ocurre en elementos individuales llamados nodos o neuronas (k), en ellas se recibe un determinado número (n) de entradas ($x_1, x_2, x_3, \dots, x_n$) que son ponderadas por un número determinado de constantes adaptables llamadas pesos sinápticos ($w_1, w_2, w_3, \dots, w_n$). Una vez que las entradas han sido ponderadas, son sumadas en el núcleo de la neurona ($\sum$) para producir lo que se conoce como entrada neta (u_k), la cual es evaluada por una función de activación (φ) y de esta forma genera la señal de salida de la neurona (y_k). Durante el procesamiento de la información, se incluye un parámetro externo conocido como sesgo o *bias* (b_k), cuyo valor aumenta o disminuye la entrada neta dependiendo si es positivo o negativo, de manera respectiva (Haykin, 1998). En términos matemáticos se puede describir una neurona k , mediante las ecuaciones 1 y 2.

$$u_k = \sum_{i=1}^n x_i w_{ki} = x_1 w_{k1} + x_2 w_{k2} + x_3 w_{k3} + \dots + x_n w_{kn} \quad (16)$$

$$y_k = \varphi(u_k + b_k) \quad (17)$$

Estudios recientes en diferentes regiones del mundo han demostrado que los modelos de RNA son eficaces para estimar y pronosticar las sequías mediante el análisis de índices como el SPI (Azizi et al., 2019; Choubin et al., 2016; el Ibrahim & Baali, 2018) y el SPEI (Mouatadid et al., 2018; Soh et al., 2018; Zhang et al., 2019). En México los estudios se han enfocado principalmente en la caracterización y análisis de los eventos de sequía, son pocos los desarrollados en el ámbito del pronóstico usando RNA como el trabajo de Ravelo et al. (2014) quienes pronosticaron la intensidad de las sequías en la región del Organismo de Cuenca Pacífico Norte mediante el SPI y el Índice Severidad de sequía de Palmer (PDSI, por sus siglas en inglés) obteniendo coeficientes de Pearson iguales o

superiores a 0.84 para pronósticos a 1 mes y a 0.60 para pronósticos a 3 meses, lo que se traduce en una buena correlación entre el índice de sequía calculado y el valor pronosticado mediante las redes neuronales y el trabajo de Villazón-Bustillos et al. (2016) donde utilizaron las redes neuronales NARX (*Nonlinear Autoregressive Exogenous*) para analizar los patrones de precipitación pluvial y poder predecir los próximos eventos de sequía en la región noroeste del estado de Chihuahua, obteniendo errores de predicción en la lluvia entre 2.35 y 12.16 mm utilizando modelos NARX, mientras que al usar modelos ARIMA los errores de predicción fueron mayores, oscilando entre 4.85 y 56.45 mm. En la cuenca del río Sonora, no existen antecedentes de estudios similares al propuesto, y se considera importante el pronóstico de las sequías en la cuenca, por un lado, porque se ubica dentro de sus límites Hermosillo, que es la capital del estado de Sonora y una de las ciudades más pobladas de la entidad y que de acuerdo con Oertel et al. (2018), ha sufrido un incremento poblacional importante en los últimos años que se ve reflejado en una demanda mayor de agua para uso agrícola, urbano e industrial. Y, por otro lado, se encuentra uno de los distritos de riego más importantes, la Costa de Hermosillo, siendo el sector agrícola el mayor usuario del agua disponible en la cuenca (Palma et al., 2015). Además de que los resultados mostrados por Hernández-Vásquez et al. (2021) del análisis de las sequías meteorológicas en la zona de estudio, indicaron que la intensidad y la frecuencia de las sequías han aumentado e identificaron eventos importantes en los años 1997, 1999, 2000 y 2011 a 2013. En este contexto, el conocimiento de las condiciones futuras de las sequías dentro de la cuenca de estudio ayudaría a crear planes de contingencia ante el impacto negativo de este fenómeno y poder evitar graves consecuencias económicas, sociales y ambientales, por lo que el objetivo de este estudio fue evaluar la aplicabilidad de las RNA para pronosticar las sequías meteorológicas en la parte media y alta de la cuenca del río Sonora, México. Para ello se utilizaron los índices SPI y SPEI a escalas temporales de 3, 6, 12 y 24 meses, para el periodo de 1974 al 2013.

4.4. Materiales y métodos

4.4.1. Área de estudio

El área de estudio tiene una superficie de 21,220 km² cubriendo la parte media y alta de la cuenca del río Sonora que se localiza en la región centro-noreste del estado con el mismo nombre (28°5'19.23" y 30°59'18.56" de latitud norte; 109°52'8.92" y 111°37'52.81" de longitud oeste) (Figura 1).

Basándose en los datos climatológicos de 19 estaciones ubicadas dentro de la zona de estudio, la precipitación media oscila entre los 300 mm y 600 mm anuales, presentándose dos periodos de lluvias, el primero y más importante en verano asociado al monzón de Norteamérica y el segundo en invierno producto del impacto de los vórtices. La temperatura media anual varía de los 12°C en las zonas montañosas hasta los 24°C en las zonas aledañas a la ciudad de Hermosillo.

4.4.2. Información climatológica

Se usaron series con datos mensuales de precipitación, temperatura máxima y temperatura mínima de 19 estaciones climatológicas (Figura 1, Tabla 1) del Servicio Meteorológico Nacional (SMN, 2019). El periodo de datos fue de 40 años, de enero de 1974 a diciembre de 2013 y se requirió de series completas por lo que la estimación de los datos faltantes se hizo por el método de la Ponderación de Distancia Inversa (IDW, por sus siglas en inglés) sugerido por la Organización Meteorológica Mundial (OMM, 2011), donde el dato ausente fue estimado con los valores observados en las cuatro, o en su defecto, tres o dos estaciones circundantes (Campos-Aranda, 1998).

En la zona de estudio se generaron isoyetas o regiones homogéneas de precipitación (Figura 1, Tabla 1), por lo que las estaciones se agruparon de manera que compartieran patrones similares en los registros anuales de lluvia. Para cada

estación de cada una de las regiones se calculó el SPI y SPEI a escalas temporales de 3, 6, 12 y 24 meses, siguiendo las metodologías desarrolladas McKee et al. (1993) y Vicente-Serrano et al. (2010), respectivamente; finalmente, para cada región se obtuvieron series temporales con los valores medios de cada uno de los índices y escala temporal trabajada. Los cálculos se realizaron en RStudio (2018) haciendo uso de la paquetería SPEI.R de Beguería & Vicente-Serrano (2017). Para más información de los cálculos y análisis de las sequías en la zona de estudio se puede consultar a Hernández-Vásquez et al. (2021).




Figura 1. Ubicación de la zona de estudio y estaciones climatológicas agrupadas por regiones homogéneas de precipitación.

Tabla 1. Estaciones climatológicas ubicadas en la zona de estudio.

Estación	Altitud	Latitud (N)	Longitud (W)	P (mm)	Tmax (°C)	Tmin (°C)	Dat. Est. (%)	Grupo/Isoyeta
26139 Hermosillo II	221	29°05'56"	110°57'14"	363.5	32.2	17.7	0.3	1 (300 -400 mm)
26121 Ures	385	29°25'37"	110°23'31"	375.6	31.8	9.1	12.1	
26016 Carbo	464	29°41'03"	110°57'18"	374.6	31.2	13.0	4.9	
26074 Querobabi	661	30°03'02"	111°01'17"	394.0	31.2	11.3	12.1	
26032 El Orégano	279	29°13'48"	110°42'21"	410.6	33.8	14.1	6.9	2a (400 -500 mm)
26274 Topahue	300	29°16'15"	110°38'09"	418.6	33.1	12.9	22.4	
26180 El Cajón	390	29°28'19"	110°44'09"	414.2	32.1	11.7	2.3	
26244 Rancho Viejo	450	29°07'37"	110°18'54"	458.6	31.1	12.4	28.1	
26199 Pueblo de Álamos	589	29°12'15"	110°08'25"	498.8	30.8	11.7	15.8	
26214 Huepac	644	29°54'46"	110°12'47"	496.5	30.1	9.7	19.7	2b (400 -500 mm)
26008 Banamichi	675	30°00'12"	110°12'54"	459.7	30.7	13.3	1.7	
26271 Sinoquipe	740	30°09'20"	110°14'42"	504.5	30.5	11.6	39.8	
26005 Arizpe	836	30°20'08"	110°10'03"	474.5	29.4	10.0	31.9	
26007 Bacanuchi	1049	30°35'56"	110°14'18"	489.1	28.0	7.4	6.2	
26145 Bacoachi	1049	30°37'54"	109°58'12"	465.5	28.0	8.2	35.3	
26198 Mazocahui	449	29°32'26"	110°07'09"	517.6	31.4	11.2	22.1	3 (500 -600 mm)
26181 Rayón	560	29°42'38"	110°34'14"	500.5	30.6	11.8	7.7	
26241 Meresichic	712	30°01'50"	110°40'30"	521.8	28.5	11.0	38.9	
26025 Cucurpe	853	30°19'50"	110°42'21"	524.7	29.6	10.3	10.4	

P= Precipitación promedio anual, Tmax= Temperatura máxima promedio,

Tmin= Temperatura mínima promedio, Dat. Est. = Datos estimados

4.4.3. Redes Neuronales Artificiales (RNA)

Para el pronóstico de los índices SPI y SPEI a diferentes escalas temporales, se evaluaron diferentes arquitecturas de redes neuronales multicapa, donde se incrementaron de manera unitaria la cantidad de neuronas en la capa de entrada ($n=3$ a 12) y en la capa oculta (de n hasta $2n +1$), los parámetros de cada modelo se estimaron usando el algoritmo de aprendizaje *RPROP+* o *RPROP-* y se usó validación cruzada de $k=10$ iteraciones para evitar el sobreajuste y aumentar la capacidad de generalización de cada modelo, tal y como se describe detalladamente a continuación.

Existen diferentes modelos de RNA, sin embargo, en este trabajo se adoptó el perceptrón multicapa (*MLP*, por sus siglas en inglés) con conexiones hacia adelante (*feed-forward*) primero por ser la arquitectura más popular y segundo por ser reconocida como una de las más poderosas para la estimación de series de tiempo de tipo hidrológicas (Achour et al., 2020). Los modelos *MLP* desarrollados se basaron en una arquitectura de tres capas de diferentes niveles con cantidades variables de neuronas en cada capa. En la capa de entrada el número de neuronas fue igual a las observaciones retrasadas en el tiempo $t-n$, donde n son los retrasos que variaron de 3 hasta 12 meses de la serie con los valores del SPI o del SPEI en cada una de las escalas temporales de 3, 6, 12 o 24 meses. En la capa de salida se asumió una sola neurona, ya que se predijo una sola variable (SPI_{t+1} o $SPEI_{t+1}$). La densidad óptima de las neuronas en la capa oculta se determinó probando diferentes cantidades que iban de n hasta $2n + 1$ en incrementos unitarios (Mishra & Desai, 2006).

Para obtener el valor de salida de la neurona se requirió de conocer su valor de activación, por lo cual se utilizó la función sigmoideal, que posee un rango continuo de valores dentro de los intervalos $[0, 1]$ y es reportada en la literatura como una de las funciones no lineales más usadas en la construcción de redes neuronales (Khan et al., 2018). Es expresada por la ecuación 3, donde u representa la suma ponderada de las entradas para una neurona y e denota la función exponencial.

$$\varphi(u) = \frac{1}{1 + e^{-u}} \quad (18)$$

Los valores de entrada de la RNA se normalizaron para que se encontraran dentro del rango la función de activación, mediante la siguiente ecuación (Bari Abarghouei et al., 2013):

$$X_{nor} = \frac{X_0 - X_{min}}{X_{max} - X_{min}} \quad (19)$$

Donde, X_0 corresponde al valor original del índice de sequía, X_{min} y X_{max} representan el valor mínimo y máximo histórico en la serie de datos originales y X_{nor} es el valor normalizado.

Durante la etapa de entrenamiento se ajustaron los pesos sinápticos de la red neuronal utilizando los algoritmos *RPROP+* (Riedmiller, 1994) y *RPROP-* (Riedmiller & Braun, 1993), que hacen referencia al método de aprendizaje *resilient propagation* (*RPROP*) que considera la propagación del error hacia atrás con y sin retroceso de peso, de forma respectiva. Este método es considerado como una versión superior de *backpropagation* al resolver los problemas de convergencia lenta y el estancamiento de los pesos de la red alrededor de óptimos locales (Prasad et al., 2013) y es reconocido por Ortiz et al. (2007) como uno de los algoritmos más apropiados para entrenar redes neuronales artificiales.

Por otra parte, Velásquez et al. (2010) mencionan que los MLP presentan algunos inconvenientes como el sobreajuste u *overfitting*, donde la red memoriza los datos de entrenamiento e incluso el ruido presente en ellos, haciendo que disminuya su capacidad de proporcionar una respuesta correcta ante datos que no se han usado durante el entrenamiento, es decir en la etapa de validación o prueba (Günther & Fritsch, 2010). Para controlar el sobreajuste, en este estudio, se utilizó la técnica de validación cruzada (*Cross Validation*), para lo cual se dividió el conjunto total de datos en $k=10$ subconjuntos, donde uno de ellos sirvió como datos de validación y el resto como datos de entrenamiento. Este proceso se repitió de manera iterativa con cada uno de los posibles subconjuntos de validación (Martín del Brio & Sanz Molina, 2001; Velásquez H. et al., 2013).

La RNA que condujo al mínimo Error Cuadrático Medio (MSE) (Gómez Guerrero & Aguayo Arias, 2019; Vargas-Castañeda et al., 2015) durante la validación, se conservó como la arquitectura óptima y su desempeño en el pronóstico de los índices de sequía se evaluó a través de diversas medidas de bondad de ajuste como el coeficiente de determinación (R^2) (Cervantes-Osornio et al., 2013; Gallegos-

Cedillo et al., 2016) y la Eficiencia de Nash–Sutcliffe (E) (Djerbouai & Souag-Gamane, 2016; Laqui et al., 2019; Soh et al., 2018). El cálculo de MSE, R^2 y E se muestra en las ecuaciones 5, 6 y 7, respectivamente:

$$MSE = \frac{1}{N} \sum_{i=1}^N (Obs_i - Est_i)^2 \quad (20)$$

$$R^2 = \frac{[\sum_{i=1}^N (Est_i - \overline{Est})(Obs_i - \overline{Obs})]^2}{[\sum_{i=1}^N (Est_i - \overline{Est})^2] [\sum_{i=1}^N (Obs_i - \overline{Obs})^2]} \quad (21)$$

$$E = 1 - \frac{\sum_{i=1}^N (Obs_i - Est_i)^2}{\sum_{i=1}^N (Obs_i - \overline{Obs})^2} \quad (22)$$

Donde *Obs* son los datos observados y $\overline{Obs}$ es la media observada, *Est* los datos estimados y $\overline{Est}$ la media estimada y *N* es el número de observaciones en el periodo considerado. Para el MSE un valor igual a cero, R^2 y E igual a 1.0 indican un ajuste perfecto del modelo y con una capacidad excelente para el pronóstico de sequías.

Para desarrollar los distintos modelos de RNA, la elección de la arquitectura óptima y el pronóstico de sequías se utilizó la paquetería Neuralnet desarrollada por Günther & Fritsch (2010) para el programa RStudio (2018).

4.5. Resultados y discusión

Los resultados son presentados por grupos de estaciones que conforman cada región homogénea de precipitación como se indica en la Tabla 1. Para cada índice (SPI o SPEI) y escala temporal (3, 6, 12 o 24 meses) de cada grupo, se probaron y evaluaron en total 1,900 modelos de RNA como se especifica en la Tabla 2 y se seleccionó aquel con el MSE mínimo durante la validación de los modelos.

Tabla 2. Modelos de redes neuronales artificiales para el pronóstico de sequías.

Entrada (n)	Neuronas en la capa de			Salida (SPI o SPEI)	Algoritmos de entrenamiento (<i>RPROP+</i> y <i>RPROP-</i>)	<i>Cross Validation</i> k=10	Modelos diferentes de RNA
	Oculto (n)	a	2n + 1)				
3	3	-	7	1	2	10	100
4	4	-	9	1	2	10	120
5	5	-	11	1	2	10	140
6	6	-	13	1	2	10	160
7	7	-	15	1	2	10	180
8	8	-	17	1	2	10	200
9	9	-	19	1	2	10	220
10	10	-	21	1	2	10	240
11	11	-	23	1	2	10	260
12	12	-	25	1	2	10	280

En la Tabla 3 se presentan los modelos de redes neuronales para el grupo 1 que alcanzaron el mejor rendimiento estadístico. Los resultados en general muestran un buen desempeño de los modelos; en la etapa de entrenamiento, el promedio de la eficiencia para una escala temporal de tres meses fue de 0.80, mientras que para 24 meses fue de 0.96. Independientemente del índice de sequía que se evaluó, durante la etapa de validación la eficiencia disminuyó en todos los casos, pero al probar las redes neuronales entrenadas y validadas con el conjunto completo de datos las eficiencias aumentaron, las mínimas se obtuvieron para escalas de 3 meses (SPI=0.78 y SPEI=0.79) y las máximas en escalas de 24 meses con valores de 0.96 y 0.97 para el SPI y SPEI, respectivamente.

El Ibrahimí & Baali (2018) exploraron la predicción de las condiciones de la sequía a corto plazo (SPI 3) y a largo plazo (SPI 12) en las estaciones climatológicas Fez-DRH y Ain Bittit ubicadas en la llanura de Saïss al norte de Marruecos, mediante seis modelos: sistema de inferencia neuro-difuso adaptativo (ANFIS), las redes neuronales artificiales de perceptrón multicapa (RNA), los sistemas vectoriales de

regresión (SVR) y cada uno combinado con el enfoque de la transformada de *Wavelet*. En general, los resultados que obtuvieron mostraron que los modelos ANFIS-Wavelet tuvieron las mejores predicciones en términos del R^2 para ambas estaciones, además de que los resultados para SPI 12 son mejores que los esperados para SPI 3 en todos los casos. Los rendimientos del R^2 obtenidos en la estación Fez-DRH de los modelos de RNA y RNA-Wavelet para el SPI 12 fueron de 0.74 y 0.87 en el entrenamiento y 0.80 y 0.83 en la validación, de forma respectiva, estos resultados son inferiores a los que se obtuvieron en este trabajo.

Tabla 3. Modelos óptimos de redes neuronales para el grupo 1.

Índice	Arquitectura óptima	Algoritmo de entrenamiento	Entrenamiento			Validación			Serie completa		
			MSE	E	R^2	MSE	E	R^2	MSE	E	R^2
SPI 3	10-14-1	<i>RPROP+</i>	0.009	0.79	0.79	0.012	0.48	0.54	0.143	0.78	0.78
SPI 6	7-10-1	<i>RPROP+</i>	0.007	0.82	0.82	0.004	0.74	0.75	0.125	0.82	0.82
SPI 12	10-14-1	<i>RPROP+</i>	0.004	0.91	0.91	0.002	0.84	0.86	0.062	0.91	0.91
SPI 24	8-17-1	<i>RPROP-</i>	0.002	0.96	0.96	0.001	0.74	0.80	0.031	0.96	0.96
SPEI 3	10-13-1	<i>RPROP-</i>	0.009	0.80	0.80	0.009	-0.07	0.51	0.145	0.79	0.79
SPEI 6	7-12-1	<i>RPROP-</i>	0.007	0.85	0.85	0.004	0.53	0.63	0.096	0.86	0.86
SPEI 12	12-15-1	<i>RPROP-</i>	0.003	0.94	0.94	0.004	0.37	0.62	0.045	0.94	0.94
SPEI 24	10-15-1	<i>RPROP-</i>	0.002	0.97	0.97	0.001	0.95	0.96	0.021	0.97	0.97

En la Figura 2 se presenta la arquitectura del modelo de RNA con el desempeño más alto estadísticamente (MSE, E y R^2) en el grupo 1, con un tiempo de retraso de 10 meses en la capa de entrada, una capa oculta de 15 neuronas y una en la capa de salida que representa el valor pronosticado del índice SPEI a una escala temporal de 24 meses. Y en la Figura 3, se muestra su rendimiento según el R^2 , durante la etapa en la que se construyó el modelo y durante su validación.




Figura 2. Arquitectura de la red neuronal para SPEI 24 del grupo 1.




Figura 3. Entrenamiento y validación de la red neuronal para SPEI 24 del grupo 1.

En el grupo de estaciones nombrado como 2a, los modelos óptimos presentaron eficiencias que van de 0.59 a 0.96 durante el entrenamiento, el mínimo se alcanzó con datos del SPI 3 y el máximo con datos del SPEI 24 y durante la validación, la eficiencia de estos modelos no varío de manera significativa alcanzando valores de 0.60 y 0.96 de manera respectiva (Tabla 4). En un estudio realizado por Mouatadid et al. (2018) aplicaron un modelo de máquina de aprendizaje extremo (ELM), una regresión lineal múltiple (MLR), una red neuronal artificial (RNA) y una regresión vectorial de soporte mínimo (LSSVR) para predecir el SPEI en seis estaciones climatológicas de una región propensa a la sequía en el este de Austria. Los resultados revelaron una mayor precisión predictiva de las RNA en comparación con las tres técnicas restantes y los pronósticos fueron mejor evaluados en el SPEI 12 que en el SPEI 3 con un R^2 durante la etapa de validación de 0.89, muy similar al obtenido en este estudio ($R^2= 0.88$).

Tabla 4. Modelos óptimos de redes neuronales para el grupo 2a.

Índice	Arquitectura óptima	Algoritmo de entrenamiento	Entrenamiento			Validación			Serie completa		
			MSE	E	R^2	MSE	E	R^2	MSE	E	R^2
SPI 3	3-5-1	<i>RPROP-</i>	0.015	0.59	0.59	0.008	0.60	0.60	0.288	0.59	0.59
SPI 6	11-18-1	<i>RPROP+</i>	0.005	0.85	0.85	0.003	0.52	0.58	0.115	0.85	0.85
SPI 12	10-18-1	<i>RPROP-</i>	0.004	0.90	0.90	0.003	0.89	0.89	0.075	0.90	0.90
SPI 24	4-4-1	<i>RPROP-</i>	0.003	0.94	0.94	0.001	0.92	0.92	0.038	0.95	0.95
SPEI 3	12-12-1	<i>RPROP-</i>	0.007	0.85	0.85	0.009	0.67	0.69	0.125	0.84	0.84
SPEI 6	12-22-1	<i>RPROP-</i>	0.003	0.93	0.93	0.007	0.58	0.75	0.059	0.93	0.93
SPEI 12	10-19-1	<i>RPROP-</i>	0.004	0.93	0.93	0.003	0.88	0.88	0.054	0.93	0.93
SPEI 24	11-11-1	<i>RPROP+</i>	0.002	0.96	0.96	0.001	0.96	0.97	0.029	0.96	0.96

En la evaluación del desempeño de los modelos de RNA con la serie completa de datos se obtuvieron valores para el R^2 que van de 0.59 a 0.95 para el SPI y de 0.84 a 0.96 para el SPEI, aumentando conforme la escala temporal del índice era mayor. La arquitectura 11-11-1 con el algoritmo de entrenamiento *RPROP+* alcanzó en promedio el rendimiento más alto (R^2 promedio = 0.97) para predecir el comportamiento de la sequía por medio del SPEI a 24 meses, mientras que el

rendimiento más bajo fue para el SPI 3 con la red de arquitectura 3-5-1 (Figura 4) y el algoritmo *RPROP*-, donde se obtuvo un R^2 de 0.59 durante el entrenamiento y 0.60 en la validación del modelo (Figura 5).




Figura 4. Arquitectura de la red neuronal para SPI 3 del grupo 2a.




Figura 5. Entrenamiento y validación de la red neuronal para SPI 3 del grupo 2a.

Los resultados de la experimentación en el grupo 2b se presentan la Tabla 5, donde se puede observar que a mayor escala temporal del SPI o SPEI el rendimiento de los modelos aumentaba, como lo indica el MSE, R^2 y la E, estos resultados concuerdan con Rezaeian-Zadeh & Tabari (2012) quienes pronosticaron el SPI a 3, 6, 9, 12 y 24 meses, en cinco estaciones climatológicas en Irán y cuyos resultados indicaron que los *MLP* pronosticaron el SPI 24 y SPI 12 con mayor precisión que los SPI a escalas de tiempo menores.

En este estudio, las eficiencias más altas en el entrenamiento fueron de 0.93 para el SPI y de 0.97 para el SPEI, ambos a escalas de 24 meses. El MSE, no supera el valor de 0.013 en ninguno de los pronósticos, por lo cual se puede aseverar que los resultados son favorables en la etapa de entrenamiento. En la validación de los modelos, las medidas de bondad de ajuste arrojaron valores superiores a 0.56 en el R^2 en todos los casos y eficiencias que van de 0.11 para el SPI 6 hasta 0.89 para el SPEI 24, mientras que en la evaluación del modelo con las series completas de datos las eficiencias y R^2 para el pronóstico de los índices de sequía fueron superiores a 0.65, con una máxima de 0.97 para el SPEI 24.

Tabla 5. Modelos óptimos de redes neuronales para el grupo 2b.

Índice	Arquitectura óptima	Algoritmo de entrenamiento	Entrenamiento			Validación			Serie completa		
			MSE	E	R^2	MSE	E	R^2	MSE	E	R^2
SPI 3	7-8-1	<i>RPROP-</i>	0.013	0.64	0.64	0.007	0.74	0.74	0.271	0.65	0.65
SPI 6	11-21-1	<i>RPROP-</i>	0.005	0.84	0.85	0.009	0.11	0.59	0.126	0.84	0.84
SPI 12	8-13-1	<i>RPROP-</i>	0.006	0.86	0.86	0.003	0.62	0.68	0.100	0.86	0.86
SPI 24	9-17-1	<i>RPROP+</i>	0.004	0.93	0.93	0.002	0.73	0.79	0.050	0.93	0.93
SPEI 3	7-15-1	<i>RPROP-</i>	0.011	0.78	0.78	0.013	0.45	0.56	0.181	0.77	0.77
SPEI 6	7-9-1	<i>RPROP+</i>	0.008	0.86	0.86	0.005	0.72	0.74	0.112	0.86	0.86
SPEI 12	9-10-1	<i>RPROP-</i>	0.005	0.91	0.91	0.003	0.81	0.84	0.065	0.92	0.92
SPEI 24	11-20-1	<i>RPROP-</i>	0.002	0.97	0.97	0.001	0.89	0.91	0.023	0.97	0.97

La Figura 6 muestra la arquitectura que obtuvo las estadísticas con mejor desempeño durante el entrenamiento y la validación que se realizaron de manera

simultánea aplicando la técnica de *Cross Validation*. Se observa en la Figura 7 que el R^2 durante el entrenamiento fue de 0.97 y 0.91 en la validación del modelo, alcanzados por la arquitectura de 11 y 20 neuronas en la capa de entrada y en la capa oculta, respectivamente. La neurona de salida obtenida fue el pronóstico del índice SPEI a 24 meses.




Figura 6. Arquitectura de la red neuronal para SPEI 24 del grupo 2b.




Figura 7. Entrenamiento y validación de la red neuronal para SPEI 24 del grupo 2b.

De acuerdo con los resultados del grupo 3, presentados en la Tabla 6, las arquitecturas 7-15-1 con *RPROP+* para el SPI 24 y 5-10-1 con *RPROP-* para el SPEI 24 fueron las mejor evaluadas con $R^2=0.96$ en el entrenamiento; sin embargo, en la etapa de validación la arquitectura 12-16-1 con *RPROP+* para el SPEI 12 fue quien obtuvo un R^2 de 0.94 y se colocó como la mejor evaluación en esta etapa. Al comparar los valores estimados por la red neuronal con los datos reales de los índices en la serie completa de datos, nuevamente quienes alcanzan las evaluaciones más altas fueron las redes para el SPI y SPEI a escalas de 24 meses con E y R^2 iguales a 0.96. Los resultados de esta investigación concuerdan con diferentes estudios como el que realizaron Poornima & Pushpalatha (2019), donde utilizaron redes neuronales recurrentes y modelos estadísticos para pronosticar las sequías por medio del SPI y SPEI en la región de Hyderabad en la India. Y donde el modelo de redes neuronales con variables adicionales como la temperatura y la humedad relativa fue seleccionado por su superioridad en el modelado de las sequías. Los datos utilizados para el cálculo de los índices a escalas de tiempo diferente (1, 6 y 12 meses) fueron de 1975 a 2013. Azizi et al. (2019) evaluaron la eficiencia de las redes neuronales artificiales frente a un método estadístico de medias móviles, para predecir las sequías en las estaciones de Ilam y Dehloran en Irán por medio del SPI en el periodo de 1983-2013. Encontraron que las RNA tuvieron mayor precisión en los pronósticos y que la arquitectura más adecuada para predecir las sequías en ambas estaciones fue 5-30-1, según sus cálculos de la raíz del error cuadrático medio, el error absoluto medio y el coeficiente de determinación para la estación Ilam fueron de 0.60, 0.55 y 0.81 para el entrenamiento y 0.56, 0.46 y 0.93 para la validación, respectivamente; en cambio para la estación Dehloran fueron de 0.60, 0.55 y 0.81 en el entrenamiento y 0.37, 0.28 y 0.99 en la validación, de manera respectiva.

Tabla 6. Modelos óptimos de redes neuronales para el grupo 3.

Índice	Arquitectura óptima	Algoritmo de entrenamiento	Entrenamiento			Validación			Serie completa		
			MSE	E	R ²	MSE	E	R ²	MSE	E	R ²
SPI 3	7-8-1	RPROP+	0.009	0.62	0.62	0.005	0.70	0.71	0.272	0.63	0.63
SPI 6	12-17-1	RPROP-	0.006	0.87	0.87	0.003	0.83	0.83	0.100	0.87	0.87
SPI 12	12-15-1	RPROP-	0.004	0.91	0.91	0.002	0.87	0.88	0.070	0.90	0.90
SPI 24	7-15-1	RPROP+	0.002	0.96	0.96	0.001	0.90	0.90	0.033	0.96	0.96
SPEI 3	8-10-1	RPROP+	0.010	0.79	0.79	0.008	0.49	0.62	0.135	0.79	0.79
SPEI 6	12-19-1	RPROP+	0.004	0.90	0.90	0.003	0.90	0.90	0.060	0.90	0.90
SPEI 12	12-16-1	RPROP+	0.005	0.91	0.91	0.002	0.93	0.94	0.048	0.91	0.91
SPEI 24	5-10-1	RPROP-	0.002	0.96	0.96	0.001	0.77	0.80	0.020	0.96	0.96

Para el grupo 3 se presenta en la Figura 8 la red neuronal que obtuvo el rendimiento más alto, con el $R^2= 0.94$ durante la validación del modelo, a pesar de que en el entrenamiento su R^2 fue de 0.91 y no fue el mejor evaluado durante esta etapa (Figura 9). Esta red se conforma por 12 neuronas en la capa de entrada, es decir, se usaron 12 retrasos en el tiempo para estimar el valor estimado del SPEI 12 y la capa oculta tiene una densidad de 16 neuronas.




Figura 8. Arquitectura de la red neuronal para SPEI 12 del grupo 3.




Figura 9. Entrenamiento y validación de la red neuronal para SPEI 12 del grupo 3.

Del análisis del SPI y SPEI realizado por Hernández-Vásquez et al. (2021) en la zona de estudio, el grupo 2b fue quien presentó la mayor ocurrencia de sequías durante el periodo comprendido de enero de 1974 a diciembre de 2013 y lo atribuyeron al impacto de diversos factores como el relieve y el comportamiento de los sistemas de vientos. En este contexto, se puede afirmar que, de la zona de estudio, la región que cubren las estaciones del grupo 2b, es la de mayor vulnerabilidad ante los impactos de las sequías y es importante prestar atención a su comportamiento futuro; por lo que, en la Figura 10 se muestra el comportamiento de las redes neuronales que durante la validación con la serie completa de datos obtuvieron el mejor desempeño en cada una de las escalas temporales trabajadas para este grupo. Se puede observar que de acuerdo con el R^2 el pronóstico del SPEI fue superior al SPI y éste aumentó conforme la escala de tiempo era mayor.




Figura 10. SPEI observado y pronosticado del grupo 2b.

En la Tabla 7 se presenta el pronóstico de los índices SPI y SPEI de los tres meses siguientes al periodo de estudio: enero, febrero y marzo de 2014 y se comparan con los registros del Monitor de Sequía de México (MSM) (CONAGUA-SMN, 2020), cuya metodología se basa en la obtención e interpretación de siete diferentes índices, integrándolos en un sistema de información geográfica y que mediante un consenso se determinan las regiones afectadas por la sequía. De acuerdo con los pronósticos de estos índices, las condiciones de sequía de la zona de estudio oscilaron entre normales (N) y moderadamente secas (D1), difiriendo con lo reportado por el MSM, donde se declararon condiciones de anormalmente secas (D0) a moderadamente secas (D1), con excepción de los municipios de Cananea y Bacoachi, ubicados en la parte alta de la cuenca, que presentaron sequías severas (D2) en la segunda quincena de marzo (CONAGUA-SMN, 2020). Para el grupo 1, el MSM declaró que las condiciones para enero, febrero y marzo fueron anormalmente secas, coincidiendo con los pronósticos del SPI 6 y SPI 24. Para el grupo 2a, 2b y 3, las sequías fueron reportadas como moderadas, esta categoría fue igual al pronóstico de los índices SPEI 12 y SPEI 24 para el grupo 2a y SPI 24 y SPEI 24 para el grupo 2b, en el caso del grupo 3 ninguno de los pronósticos coincidió con los reportados por el MSM, sin embargo, con los índices SPI y SPEI a escalas de 12 y 24 meses se alcanzaron condiciones de anormalmente seco, que se acercan a las reportadas por la CONAGUA-SMN (2020). De manera general, se observa que, en este estudio, los pronósticos obtenidos usando las RNA para el SPI arrojan condiciones menos secas que el SPEI, por lo que estas últimas se aproximan más a las condiciones reales según el MSM, siendo éstas aún más cercanas al usar escalas de 24 meses.

Tabla 7. Pronóstico de los índices SPI y SPEI de enero a marzo de 2014.

Grupo	Pronóstico 2014	MSM	SPI 3	SPEI 3	SPI 6	SPEI 6	SPI 12	SPEI 12	SPI 24	SPEI 24
1	Enero	D0	N	N	N	D0	N	D1	D0	D1
	Febrero	D0	N	D0	N	D0	N	D0	D0	D1
	Marzo	D0	N	D0	D0	D0	N	D0	D0	D1
2a	Enero	D1	N	D0	N	D0	N	D1	D0	D1
	Febrero	D1	N	D1	D0	D1	D0	D1	D0	D1
	Marzo	D1	N	D1	D1	D1	D0	D1	D0	D1
2b	Enero	D1	D0	N	N	N	N	N	D1	D1
	Febrero	D1	D0	N	N	N	N	N	D1	D1
	Marzo	D1	N	N	N	N	N	N	D1	D1
3	Enero	D1	N	N	N	N	D0	D0	D0	D0
	Febrero	D1	N	N	D0	N	D0	D0	D0	D0
	Marzo	D1	N	N	D0	D0	D0	D0	D0	D0

N= Condiciones normales, D0= Anormalmente seco, D1= Moderadamente seco

4.6. Conclusiones

Usar la técnica de Validación Cruzada (*Cross Validation*) permitió determinar las arquitecturas óptimas de los modelos de RNA que lograron generalizar el comportamiento de los datos observados sin un sobreajuste (*overfitting*) en el comportamiento de los modelos. Se entrenó con el 90% de los datos y se validó con el 10% restante, logrando errores relativamente pequeños, donde el valor del MSE no superó a 0.015 en ninguno de los casos evaluados.

En el pronóstico de los índices de sequía se obtuvieron R^2 superiores a 0.59 durante la etapa de entrenamiento y 0.51 durante la validación, por lo que se puede aseverar que las habilidades predictivas de los modelos de RNA fueron satisfactorias.

Los modelos de RNA presentaron mayor precisión en el pronóstico de los índices a escalas de 24 meses que en aquellos que fueron trabajados en escalas de tiempo

menores, probablemente se pueda atribuir a que existe alta variabilidad de las condiciones hidro climáticas a corto plazo y se observó que las eficiencias predictivas de estos modelos fueron superiores en el SPEI, demostrando la importancia de incluir la demanda evaporativa en el balance de humedad.

Este estudio contribuyó con un enfoque novedoso en el pronóstico de las sequías a partir del análisis del SPI y SPEI, usando modelos de aprendizaje automático como las redes neuronales artificiales. Los resultados de este trabajo son importantes y útiles para la planificación y gestión de los recursos hídricos de la zona de estudio.

Las futuras investigaciones en este tema podrían centrarse en analizar el impacto que tendría en el pronóstico y precisión de los modelos de RNA incluir fenómenos atmosféricos de impacto global como El Niño-Oscilación del Sur, la Oscilación Decadal del Pacífico, la Oscilación del Atlántico Norte y el cambio climático.

4.7. Agradecimientos

Al Consejo Nacional de Ciencia y Tecnología (CONACyT) por la beca otorgada para la realización de este estudio.

4.8. Literatura citada

- Achour, K., Meddi, M., Zeroual, A., Bouabdelli, S., Maccioni, P., & Moramarco, T. (2020). Spatio-temporal analysis and forecasting of drought in the plains of northwestern Algeria using the standardized precipitation index. *Journal of Earth System Science*, 129(1), 42. <https://doi.org/10.1007/s12040-019-1306-3>
- Anshuka, A., van Ogtrop, F. F., & Willem Vervoort, R. (2019). Drought forecasting through statistical models using standardised precipitation index: a systematic

- review and meta-regression analysis. *Natural Hazards*, 97, 955–977.
<https://doi.org/10.1007/s11069-019-03665-6>
- ASCE. (2000). Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), 115–123.
- Azizi, E., Tavakoli, M., Karimi, H., & Faramarzi, M. (2019). Evaluating the efficiency of the neural network to other methods in predicting drought in arid and semi-arid regions of western Iran. *Arabian Journal of Geosciences*, 12(15).
<https://doi.org/10.1007/s12517-019-4654-z>
- Bari Abarghouei, H., Reza Kousari, M., & Asadi Zarch, M. A. (2013). Prediction of drought in dry lands through feedforward artificial neural network abilities. *Arabian Journal of Geosciences*, 6(5), 1417–1433.
<https://doi.org/10.1007/s12517-011-0445-x>
- Beguiría, S., & Vicente-Serrano, S. M. (2017). *Calculation of Standardised Precipitation-Evapotranspiration index* (1.7; Issue June). <http://sac.csic.es/spei>
- Campos-Aranda, D. F. (1998). *Procesos del ciclo hidrológico* (3rd ed.). Facultad de Ingeniería. Universidad Autónoma de San Luis Potosí.
- Castillo-Castillo, M., Ibáñez-Castillo, L. A., Valdés, J. B., Arteaga-Ramírez, R., & Vázquez-Peña, M. A. (2018). Pronóstico de sequías meteorológicas con Filtro de Kalman discreto en la cuenca del río Fuerte, México. *Agrociencia*, 52(7), 911–932.
- Cervantes-Osornio, R., Arteaga-Ramírez, R., Vázquez-Peña, M. A., Ojeda-Bustamante, W., & Quevedo-Nolasco, A. (2013). Modelos Hargreaves Priestley-Taylor y redes neuronales artificiales en la estimación de la evapotranspiración de referencia. *Ingeniería, Investigación y Tecnología*, 14(2), 163–176.
[https://doi.org/10.1016/s1405-7743\(13\)72234-0](https://doi.org/10.1016/s1405-7743(13)72234-0)

- Choubin, B., Malekian, A., & Golshan, M. (2016). Application of several data-driven techniques to predict a standardized precipitation index. *Atmosfera*, 29(2), 121–128. <https://doi.org/10.20937/ATM.2016.29.02.02>
- CONAGUA-SMN. (2020). *Monitor de Sequía de México (MSM)*. Comisión Nacional Del Agua, Sistema Meteorológico Nacional. <https://smn.conagua.gob.mx/es/climatologia/monitor-de-sequia/monitor-de-sequia-en-mexico>
- Djebbouai, S., & Souag-Gamane, D. (2016). Drought forecasting using Neural Networks, Wavelet Neural Networks, and Stochastic Models: Case of the Algerois Basin in North Algeria. *Water Resources Management*, 30(7), 2445–2464. <https://doi.org/10.1007/s11269-016-1298-6>
- Gallegos-Cedillo, J., Arteaga-Ramírez, R., Vázquez-Peña, M. A., & Juárez-Méndez, J. (2016). Estimation of missing daily precipitation and maximum and minimum temperature records in San Luis Potosí. *Ingeniería Agrícola y Biosistemas*, 8(1), 3–16. <https://doi.org/10.5154/r.inagbi.2015.11.008>
- Gómez Guerrero, J. S., & Aguayo Arias, M. I. (2019). Performance evaluation of rainfall data fill-in methods in two morphostructural areas of south-central Chile. *Investigaciones Geográficas*, 99. <https://doi.org/10.14350/rig.59837>
- Günther, F., & Fritsch, S. (2010). Neuralnet: Training of neural networks. *R Journal*, 2(1), 30–38. <https://doi.org/10.32614/rj-2010-006>
- Haykin, S. (1998). *Neural networks: a comprehensive foundation* (2nd ed.). Prentice Hall.
- Hernández-Vásquez, C. C., Ibáñez-Castillo, L. A., Gómez-Díaz, J. D., & Arteaga-Ramírez, R. (2021). Analysis of meteorological droughts in the Sonora River Basin, Mexico. *Atmósfera*. <https://doi.org/https://doi.org/10.20937/ATM.52954>

- el Ibrahim, A., & Baali, A. (2018). Application of several artificial intelligence models for forecasting meteorological drought using the standardized precipitation index in the Saïss Plain (Northern Morocco). *International Journal of Intelligent Engineering and Systems*, 11(1), 267–275. <https://doi.org/10.22266/ijies2018.0228.28>
- Khan, M. M. H., Muhammad, N. S., & El-Shafie, A. (2018). Wavelet-ANN versus ANN-based model for hydrometeorological drought forecasting. *Water (Switzerland)*, 10(8), 1–21. <https://doi.org/10.3390/w10080998>
- Laqui, W., Zubieta, R., Rau, P., Mejía, A., Lavado, W., & Ingol, E. (2019). Can artificial neural networks estimate potential evapotranspiration in Peruvian highlands? *Modeling Earth Systems and Environment*, 5(4), 1911–1924. <https://doi.org/10.1007/s40808-019-00647-2>
- Martín del Brio, B., & Sanz Molina, A. (2001). *Redes neuronales y sistemas difusos*. Alfaomega.
- McCulloch, W. S., & Pitts, W. (1943). A logic calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115–133. <https://doi.org/10.1007/BF02478259>
- McKee, T. B., Doesken, N. J., & John, K. (1993). The relationship of drought frequency and duration to time scales. *Eighth Conference on Applied Climatology*, 17–22.
- Mishra, A. K., & Desai, V. R. (2006). Drought forecasting using feed-forward recursive neural network. *Ecological Modelling*, 198(1–2), 127–138. <https://doi.org/10.1016/j.ecolmodel.2006.04.017>
- Mishra, Ashok K., & Singh, V. P. (2011). Drought modeling - A review. *Journal of Hydrology*, 403(1–2), 157–175. <https://doi.org/10.1016/j.jhydrol.2011.03.049>

- Mouatadid, S., Raj, N., Deo, R. C., & Adamowski, J. F. (2018). Input selection and data-driven model performance optimization to predict the Standardized Precipitation and Evaporation Index in a drought-prone region. *Atmospheric Research*, 212(May), 130–149. <https://doi.org/10.1016/j.atmosres.2018.05.012>
- Oertel, M., Meza, F. J., Gironás, J., Scott, C. A., Rojas, F., & Pineda-Pablos, N. (2018). Drought propagation in semi-arid river basins in Latin America: Lessons from Mexico to the Southern Cone. *Water (Switzerland)*, 10(11), 1–21. <https://doi.org/10.3390/w10111564>
- OMM. (2011). Guía de prácticas climatológicas. In *Organización Meteorológica Mundial* (Vol. 100).
- OMM, O. M. M., & Asociación Mundial para el Agua. (2016). Manual de indicadores e índices de sequía. In *Programa de gestión integrada de sequías, Serie 2 de herramientas y directrices para la gestión integrada de sequías*.
- Ortíz, D., Villa, F., & Velásquez, J. (2007). A Comparison between Evolutionary Strategies and RPROP for Estimating Neural Networks. *Avances En Sistemas e Informática*, 4(2), 135–144.
- Palma, A., González, F., & Cruickshank, C. (2015). Managed aquifer recharge as a key element in Sonora River basin management, Mexico. *Journal of Hydrologic Engineering*, 20(3), 1–10. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001114](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001114)
- Poornima, S., & Pushpalatha, M. (2019). Drought prediction based on SPI and SPEI with varying timescales using LSTM recurrent neural network. *Soft Computing*, 23(18), 8399–8412. <https://doi.org/10.1007/s00500-019-04120-1>
- Prasad, N., Singh, R., & Lal, S. P. (2013). Comparison of back propagation and resilient propagation algorithm for spam classification. *Proceedings of*

International Conference on Computational Intelligence, Modelling and Simulation, 29–34. <https://doi.org/10.1109/CIMSim.2013.14>

Ravelo, A. C., Sanz Ramos, R., & Douriet Cárdenas, J. C. (2014). Detección, evaluación y pronóstico de las sequías en la región del Organismo de Cuenca Pacífico Norte, México. *Agriscientia*, 31(1), 11–24.

Rezaeian-Zadeh, M., & Tabari, H. (2012). MLP-based drought forecasting in different climatic regions. *Theoretical and Applied Climatology*, 109(3–4), 407–414. <https://doi.org/10.1007/s00704-012-0592-3>

Riedmiller, M. (1994). Advanced supervised learning in multi-layer perceptrons - from backpropagation to adaptive learning algorithms. *International Journal of Computer Standards and Interfaces*, 16, 265–278.

Riedmiller, M., & Braun, H. (1993). A direct adaptive method for faster backpropagation learning: The RPROP algorithm. *Proceedings of the IEEE International Conference on Neural Networks (ICNN)*, 586–591. <https://doi.org/10.1109/icnn.1993.298623>

RStudio. (2018). *RStudio: Integrated Development Environment for R*. RStudio, Inc. <http://www.rstudio.com/>

SMN. (2019). *Red de Estaciones Climatológicas. Climatología mensual*. México, DF. Servicio Meteorológico Nacional. <http://smn1.conagua.gob.mx/climatologia/Mensuales/>

Soh, Y. W., Koo, C. H., Huang, Y. F., & Fung, K. F. (2018). Application of artificial intelligence models for the prediction of standardized precipitation evapotranspiration index (SPEI) at Langat River Basin, Malaysia. *Computers and Electronics in Agriculture*, 144(May 2017), 164–173. <https://doi.org/10.1016/j.compag.2017.12.002>

- Vargas-Castañeda, G., Ibáñez-Castillo, L. A., & Arteaga-Ramírez, R. (2015). Development, classification and trends in rainfall-runoff modeling. *Ingeniería Agrícola y Biosistemas*, 7(1), 5–21. <https://doi.org/10.5154/r.inagbi.2015.03.002>
- Velásquez H., J. D., Fonnegra R., Y., & Villa G., F. A. (2013). Pronóstico de series de tiempo con redes neuronales regularizadas y validación cruzada. *Revista Vinculos*, 10(1), 267–279.
- Velásquez, J. D., Villa, F. A., & Souza, R. C. (2010). Time series forecasting using cascade correlation networks. *Ingeniería e Investigación*, 30(1), 157–162.
- Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. *Journal of Climate*, 23(7), 1696–1718. <https://doi.org/10.1175/2009JCLI2909.1>
- Villazón-Bustillos, D., Rubio-Arias, H. O., Ortega-Gutiérrez, J. A., Rentería-Villalobos, M., González-Gurrula, L. C., & Pinales-Munguia, A. (2016). Análisis en series de tiempo para el pronóstico de sequía en la región noroeste del estado de Chihuahua. *Ecosistemas y Recursos Agropecuarios*, 3(9), 307–315.
- Wilhite, D. A., & Glantz, M. H. (1985). Understanding the drought phenomenon: The role of definitions. *Water International*, 10(3), 111–120. <https://doi.org/10.1080/02508068508686328>
- Zhang, R., Chen, Z. Y., Xu, L. J., & Ou, C. Q. (2019). Meteorological drought forecasting based on a statistical model with machine learning techniques in Shaanxi province, China. *Science of the Total Environment*, 665, 338–346. <https://doi.org/10.1016/j.scitotenv.2019.01.431>