

**Pronóstico de sequías meteorológicas usando redes neuronales artificiales en la cuenca del río Sonora, México**

**Forecast of meteorological droughts with neural networks in Sonora watershed, Mexico**

Claudio César Hernández-Vásquez<sup>1</sup>, ORCID: <https://orcid.org/0000-0003-3931-8780>

Laura Alicia Ibáñez-Castillo<sup>2</sup>, ORCID: <https://orcid.org/0000-0001-9287-655X>

Ramón Arteaga-Ramírez<sup>3</sup>, ORCID: <https://orcid.org/0000-0001-9459-3588>

Alejandro Ismael Monterroso-Rivas<sup>4</sup>, ORCID: <https://orcid.org/0000-0003-4348-8918>

Rocío Cervantes-Osornio<sup>5</sup>, ORCID: <https://orcid.org/0000-0003-2597-4517>

<sup>1</sup>Universidad Autónoma Chapingo, Texcoco, México,  
[claudiohdezvqz@gmail.com](mailto:claudiohdezvqz@gmail.com)

<sup>2</sup>Universidad Autónoma Chapingo, Texcoco, México, libacas@gmail.com

<sup>3</sup>Universidad Autónoma Chapingo, Texcoco, México, arteagarr@gmail.com

<sup>4</sup>Universidad Autónoma Chapingo, Texcoco, México, aimrivas@gmail.com

<sup>5</sup>Campo Experimental Valle de México-INIFAP, Coatlinchán, México, rcervanteso@hotmail.com

Autor para correspondencia: Claudio César Hernández-Vásquez, 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 el 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 a 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 éste 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).

### **Abstract**

Droughts are hydrometeorological hazards that are characterized by an abnormal and persistent humidity deficit. In the last years, this hazard has been present more frequently and with more severity levels, producing negative impacts on the ecosystem, agriculture, livestock, and society. Therefore, its monitoring and forecast, must be part of integral planning, preparation, and mitigation of its adverse effects at local, regional, and national levels. In Mexico, most of the drought studies are focused on 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 the Sonora

River watershed. SPI and SPEI index were used, on scales of 3, 6, 12, and, 24 months, for the 1974 to 2013 period of years. Forecast results showed that ANN has 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).

Recibido: 19/02/2021

Aceptado: 11/05/2021

## 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, Sanz-Ramos, & Douriet-Cárdenas, 2014). Para su estudio y monitoreo se han empleado índices como una herramienta para evaluar sus principales características, como intensidad y 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, Doesken y John (1993), y es recomendado por la Organización Meteorológica Mundial (OMM) como punto de partida para la vigilancia de la sequía (OMM & GWP, 2016); se calcula con base en los registros mensuales de precipitación; en cambio, el SPEI fue propuesto por Vicente-Serrano, Beguería y López-Moreno (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, van Ogtrop, & Willem-Vervoort, 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, Ibáñez-Castillo, Valdés, Arteaga-Ramírez, & Vázquez-Peña, 2018).

Mishra y 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 y Pitts (1943) hace más de setenta años y que ha venido experimentando un gran resurgimiento desde inicios de la década de 1990 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 cuya estructura y funcionamiento están 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). Se consideran 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 (Djerbouai & 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, se suman en el núcleo de la neurona ( $\Sigma$ ) para producir lo que se conoce como entrada neta ( $u_k$ ), la cual es evaluada por una función de activación ( $\varphi$ ) 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, respectivamente (Haykin, 1998). En términos matemáticos, se puede describir una neurona  $k$  mediante las ecuaciones (1) y (2):

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

$$y_k = \varphi(u_k + b_k) \quad (2)$$

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, Tavakoli, Karimi, & Faramarzi, 2019; Choubin, Malekian, & Golshan, 2016; El-Ibrahimi & Baali, 2018) y el SPEI (Mouatadid, Raj, Deo, & Adamowski, 2018; Soh, Koo, Huang, & Fung, 2018; Zhang, Chen, Xu, & Ou, 2019). En México, los estudios se han enfocado en la caracterización

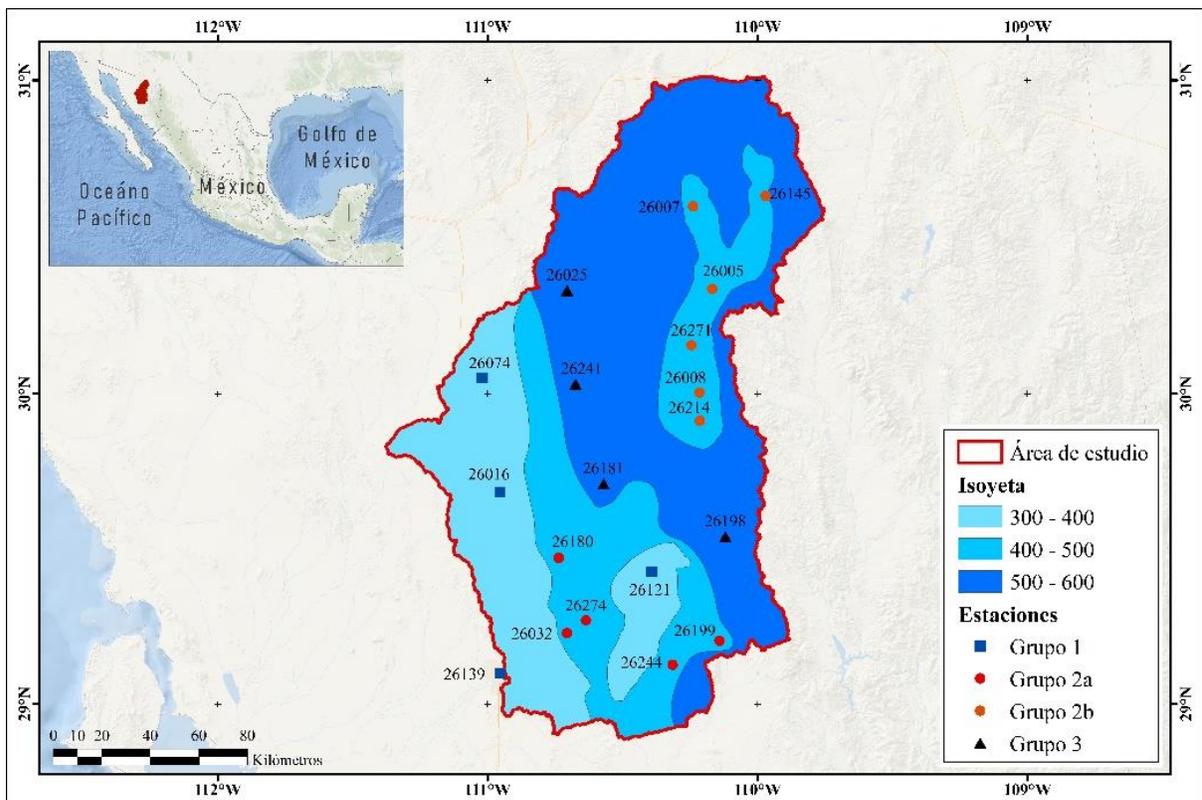
y análisis de los eventos de sequía, son pocos los desarrollados en el ámbito del pronóstico usando RNA como el trabajo de Ravelo *et al.* (2014), quienes pronosticaron la intensidad de las sequías en la región del Organismo de Cuenca Pacífico Norte mediante el SPI y el Índice Severidad de Sequía de Palmer (PDSI, por sus siglas en inglés) obteniendo coeficientes de Pearson iguales o superiores a 0.84 para pronósticos a un mes y a 0.60 para pronósticos a tres 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, González, & Cruickshank, 2015). Además de que los resultados mostrados por Hernández-Vásquez, Ibáñez-Castillo, Gómez-Díaz y Arteaga-Ramírez (2021) del análisis de las sequías meteorológicas en la zona de estudio indicaron que la intensidad y frecuencia de las sequías han aumentado e identificaron eventos importantes en los años 1997, 1999, 2000 y de 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 a 2013.

## **Materiales y métodos**

### **Área de estudio**

El área de estudio tiene una superficie de 21 220 km<sup>2</sup> 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).



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

Basándose en los datos climatológicos de 19 estaciones ubicadas dentro de la zona de estudio, la precipitación media oscila entre los 300 y 600 mm anuales, presentándose dos periodos de lluvias: el primero y más importante en verano asociado con el 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.

## **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).

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

Estación		Altitud	Latitud	Longitud	P	Tmax	Tmin	Dat. est.	Grupo/isoyeta
			(N)	(W)	(mm)	(°C)	(°C)	(%)	
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	2a (400 -500 mm)
26032	El Orégano	279	29°13'48"	110°42'21"	410.6	33.8	14.1	6.9	
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	2b (400 -500 mm)
26214	Huepac	644	29°54'46"	110°12'47"	496.5	30.1	9.7	19.7	
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	3 (500 -600 mm)
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	
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

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 por 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 y 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).

## 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 a 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 conocer su valor de activación, por lo cual se utilizó la función sigmoïdal, 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, Muhammad, & El-Shafie, 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:

$$\varphi(u) = \frac{1}{1+e^{-u}} \quad (3)$$

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, Reza-Kousari, & Asadi-Zarch, 2013):

$$X_{nor} = \frac{X_0 - X_{min}}{X_{max} - X_{min}} \quad (4)$$

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 se considera 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, Singh, & Lal, 2013) y es reconocido por Ortiz, Villa y Velásquez (2007) como uno de los algoritmos más apropiados para entrenar redes neuronales artificiales.

Por otra parte, Velásquez, Villa y Souza (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, Fonnegra, & Villa, 2013).

La RNA que condujo al mínimo error cuadrático medio (*MSE*) (Gómez-Guerrero & Aguayo-Arias, 2019; Vargas-Castañeda, Ibáñez-Castillo, & Arteaga-Ramírez, 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, Arteaga-Ramírez, Vázquez-Peña, Ojeda-Bustamante, & Quevedo-Nolasco, 2013; Gallegos-Cedillo, Arteaga-Ramírez, Vázquez-Peña, & Juárez-Méndez, 2016) y la eficiencia de Nash-Sutcliffe (*E*) (Djebouai & 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:

$$MSE = \frac{1}{N} \sum_{i=1}^N (Obs_i - Est_i)^2 \quad (5)$$

$$R^2 = \frac{[\sum_{i=1}^N (Est_i - \overline{Est})(Obs_i - \overline{Obs})]^2}{[\sum_{i=1}^N (Est_i - \overline{Est})^2][\sum_{i=1}^N (Obs_i - \overline{Obs})^2]} \quad (6)$$

$$E = 1 - \frac{\sum_{i=1}^N (Obs_i - Est_i)^2}{\sum_{i=1}^N (Obs_i - \overline{Obs})^2} \quad (7)$$

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*<sup>2</sup> 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 y Fritsch (2010) para el programa RStudio (2018).

## 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.

Neuronas en la capa de				Algoritmos de entrenamiento	<i>Cross Validation</i>	Modelos diferentes de RNA	
Entrada	Oculta		Salida				
( <i>n</i> )	( <i>n</i> )	<i>a</i>	( $2n + 1$ )	(SPI o SPEI)	( <i>RPROP+</i> y <i>RPROP-</i> )	<i>k</i> = 10	
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 tres 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.

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

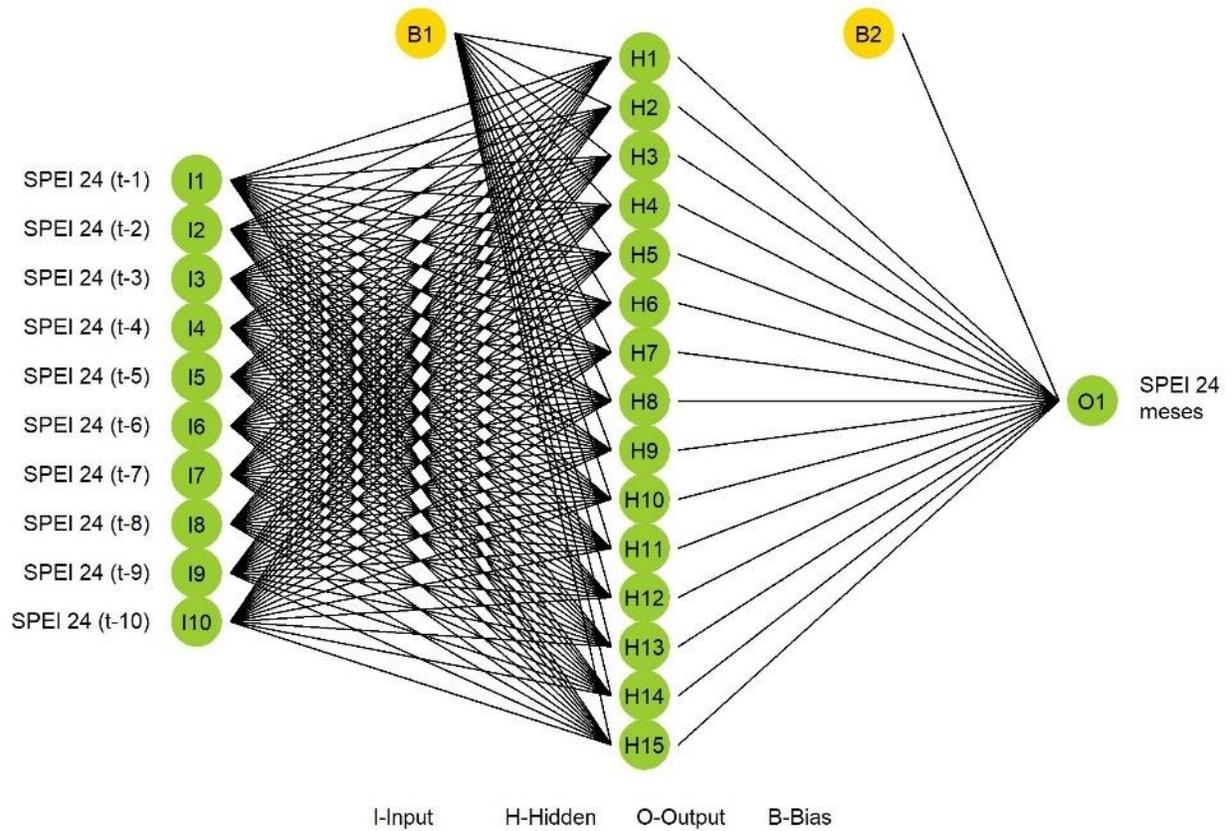
Índice	Arquitectura óptima	Algoritmo de entrenamiento	Entrenamiento			Validación			Serie completa		
			MSE	E	R <sup>2</sup>	MSE	E	R <sup>2</sup>	MSE	E	R <sup>2</sup>
SPI 3	10-14-1	RPROP+	0.009	0.79	0.79	0.012	0.48	0.54	0.143	0.78	0.78
SPI 6	7-10-1	RPROP+	0.007	0.82	0.82	0.004	0.74	0.75	0.125	0.82	0.82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

SPEI 12	12-15-1	RPROP-	0.003	0.94	0.94	0.004	0.37	0.62	0.045	0.94	0.94
SPEI 24	10-15-1	RPROP-	0.002	0.97	0.97	0.001	0.95	0.96	0.021	0.97	0.97

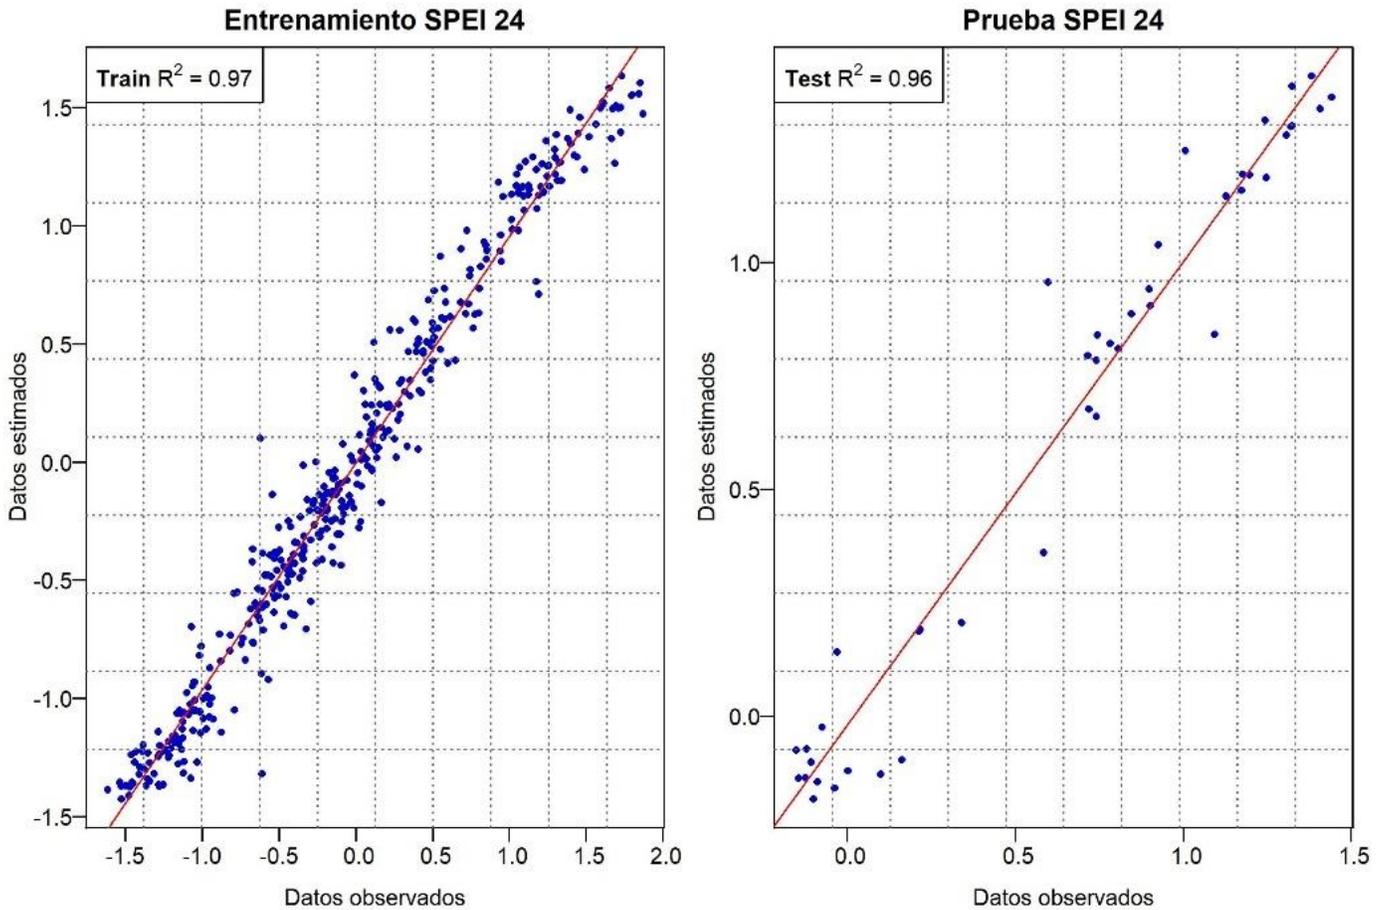
El-Ibrahimi and Baali (2018) exploraron la predicción de las condiciones de la sequía a corto plazo (SPI 3) y a largo plazo (SPI 12) en las estaciones climatológicas Fez-DRH y Ain Bittit ubicadas en la llanura de Saïss al norte de Marruecos, mediante seis modelos: sistema de inferencia neuro-difuso adaptativo (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. Por su parte, Castillo-Castillo *et al.* (2018) realizaron el pronóstico del SPI y del SPEI para 14 estaciones meteorológicas de la cuenca del río Fuerte, ubicada en el noroeste de México, mediante la implementación del algoritmo del filtro de Kalman discreto (DKF). Sus resultados coinciden con este estudio, al obtener mejores pronósticos para escalas de 12 y 24 meses, y al pronosticar el SPEI. La eficiencia de sus pronósticos para 12

y 24 meses fue de 0.92 y 0.96, ligeramente menor a los alcanzados en este trabajo.

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. 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; durante la validación, la eficiencia de estos modelos no varió de manera significativa alcanzando valores de 0.60 y 0.96 de manera

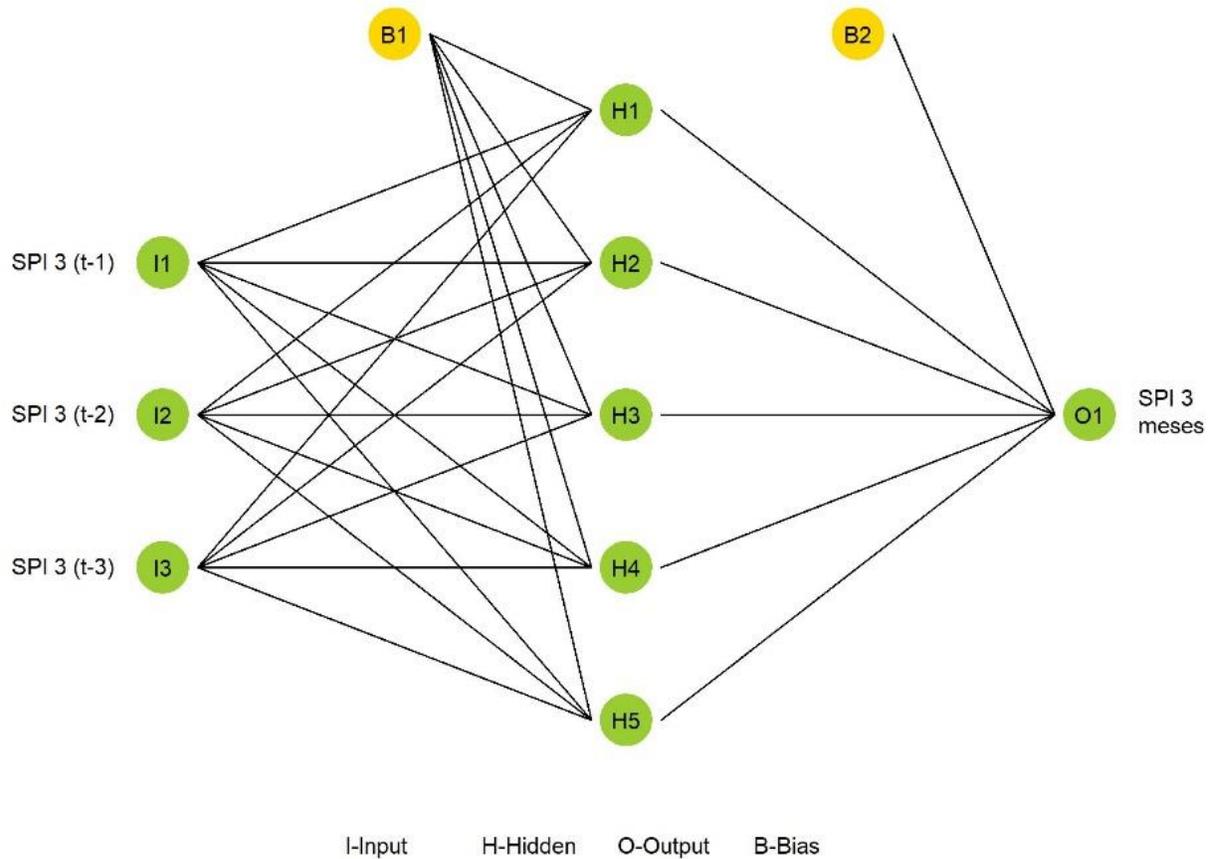
respectiva (Tabla 4). En un estudio realizado por Mouatadid *et al.* (2018) aplicaron un modelo de máquina de aprendizaje extremo (ELM), una regresión lineal múltiple (MLR), una red neuronal artificial (RNA) y una regresión vectorial de soporte mínimo (LSSVR) para predecir el SPEI en seis estaciones 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 ( $R^2 = 0.88$ ). De manera similar, en el trabajo de Villazón-Bustillos *et al.* (2016), las redes neuronales del tipo NARX se posicionaron por encima de los modelos ARIMA, al obtener mayor precisión en el pronóstico de la precipitación en la región noroeste del estado de Chihuahua. Los errores predictivos oscilaron entre 2.35 y 12.16 mm utilizando modelos NARX, mientras que al usar modelos ARIMA fluctuaron entre 4.85 y 56.45 mm.

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

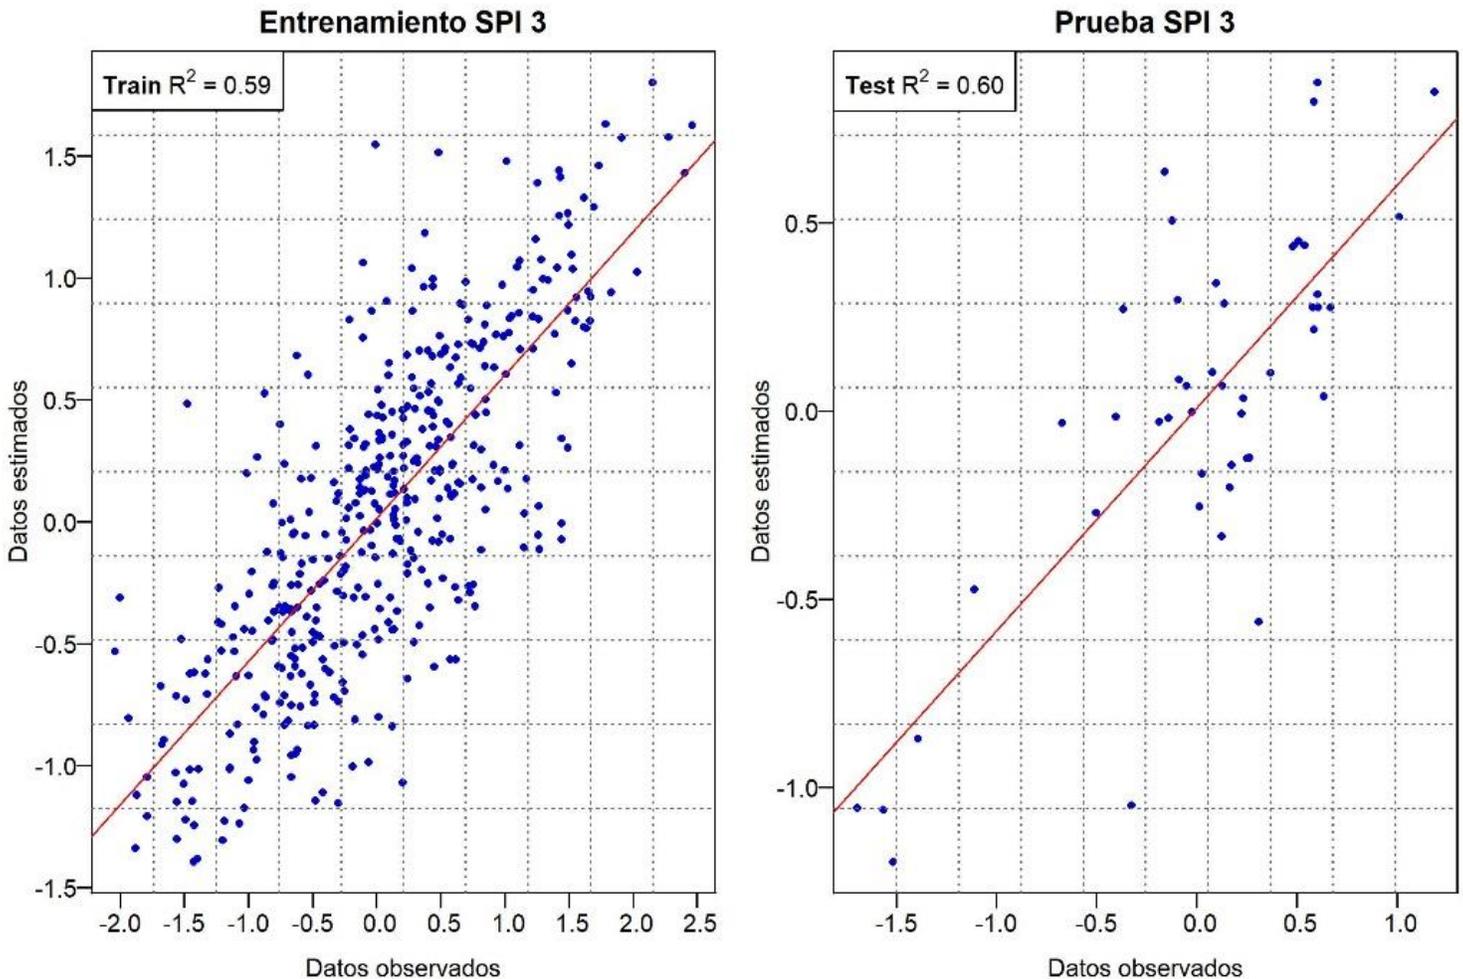
Índice	Arquitectura óptima	Algoritmo de entrenamiento	Entrenamiento			Validación			Serie completa		
			MSE	E	$R^2$	MSE	E	$R^2$	MSE	E	$R^2$
SPI 3	3-5-1	RPROP-	0.015	0.59	0.59	0.008	0.60	0.60	0.288	0.59	0.59
SPI 6	11-18-1	RPROP+	0.005	0.85	0.85	0.003	0.52	0.58	0.115	0.85	0.85

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 en 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 y 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.

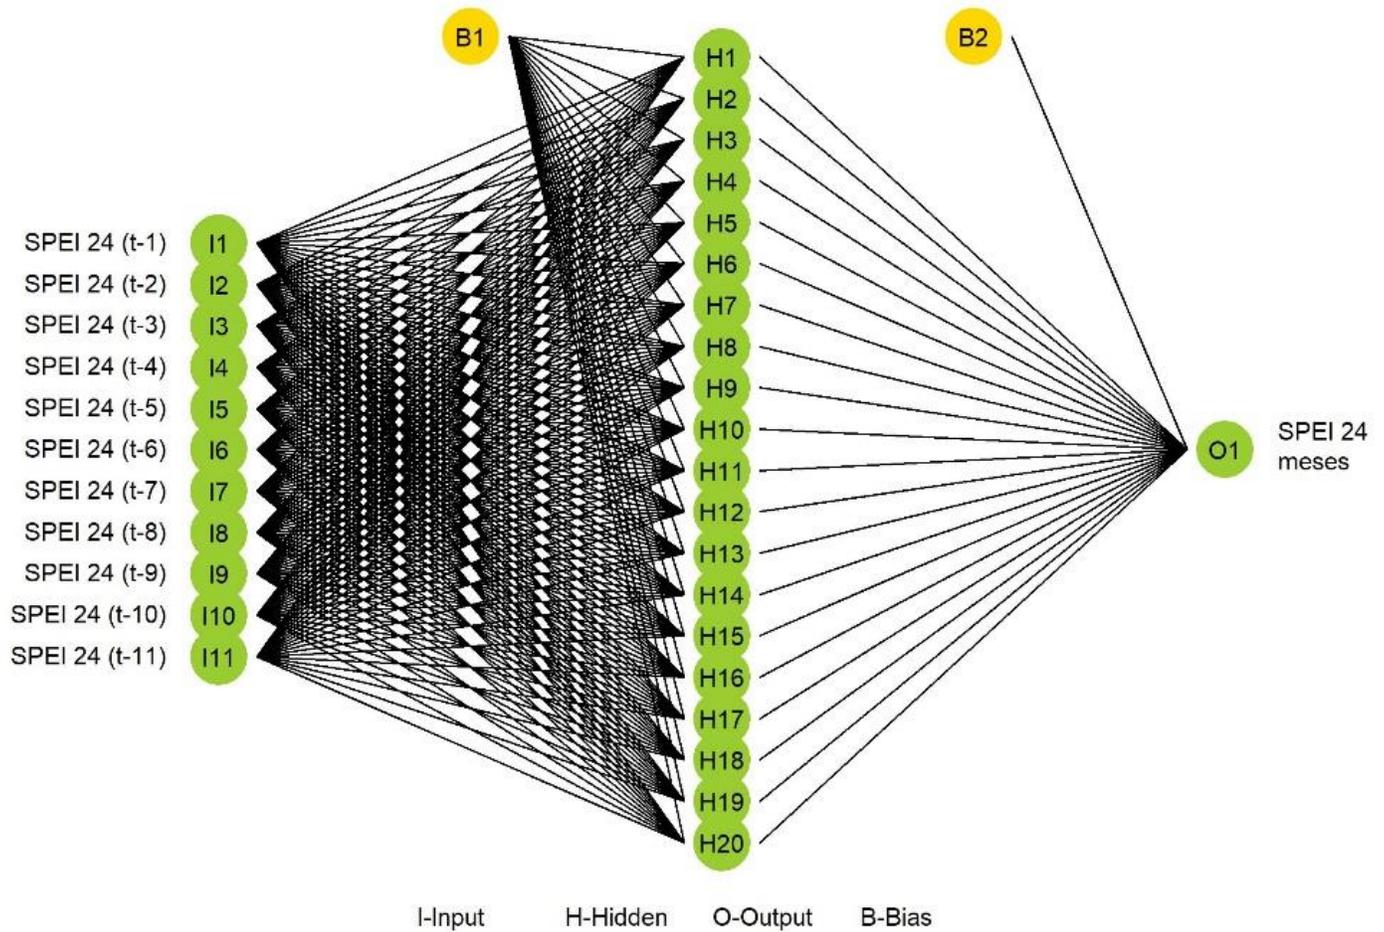
**Tabla 5.** Modelos óptimos de redes neuronales para el grupo 2b.

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

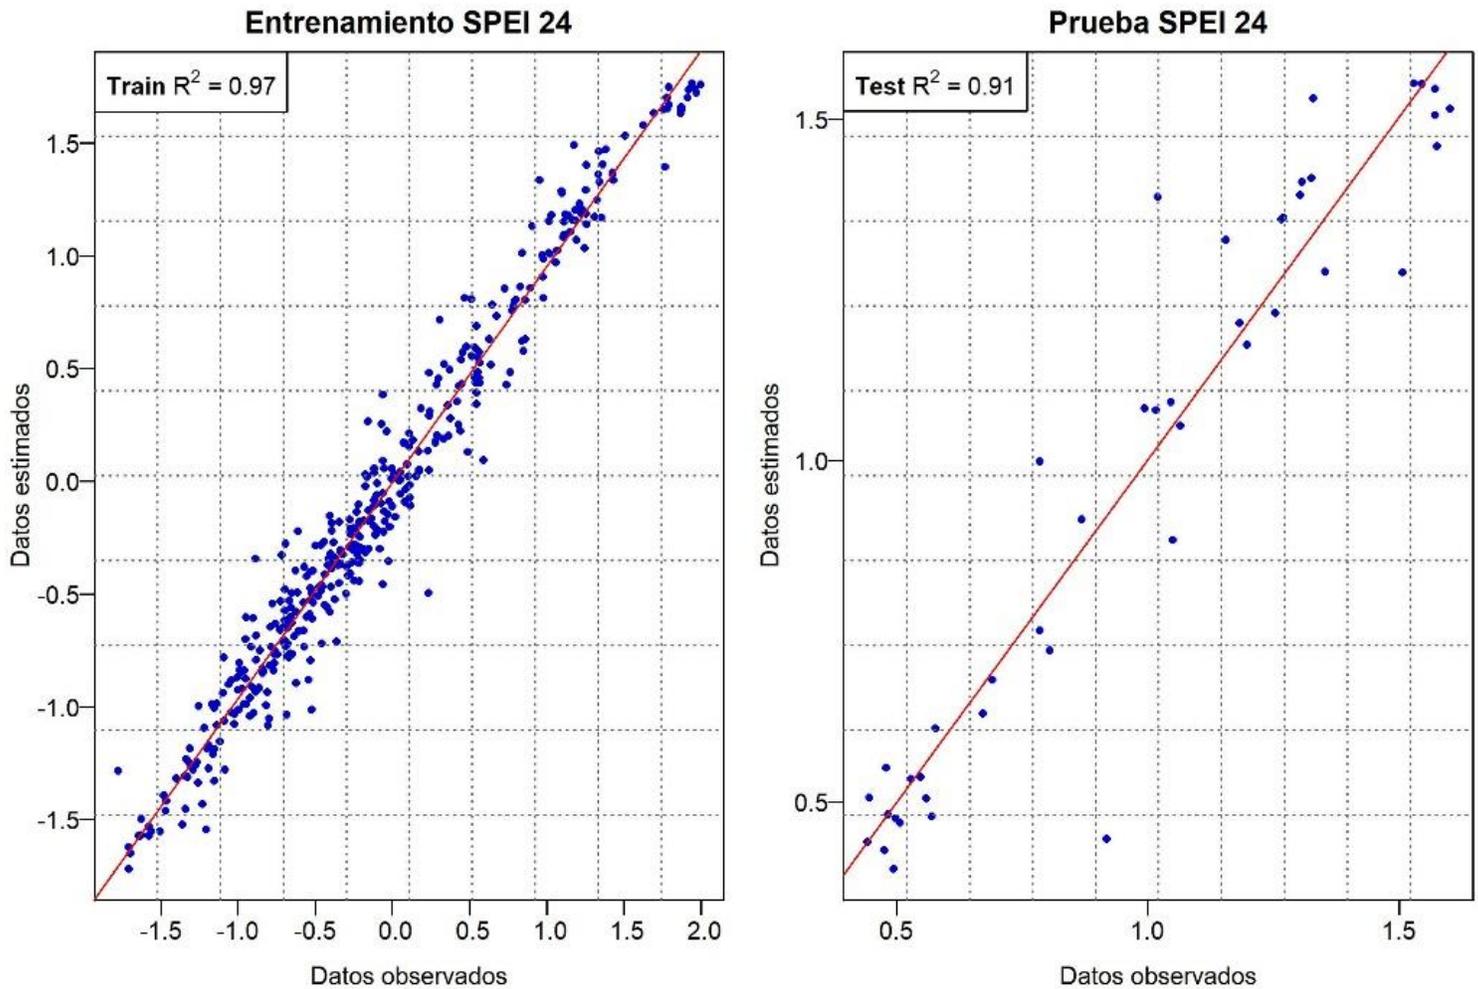
En este estudio, las eficiencias más altas en el entrenamiento fueron de 0.93 para el SPI y de 0.97 para el SPEI, ambos a escalas de 24 meses. El  $MSE$ , no supera el valor de 0.013 en ninguno de los pronósticos, por lo

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.

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 la que 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 y 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.

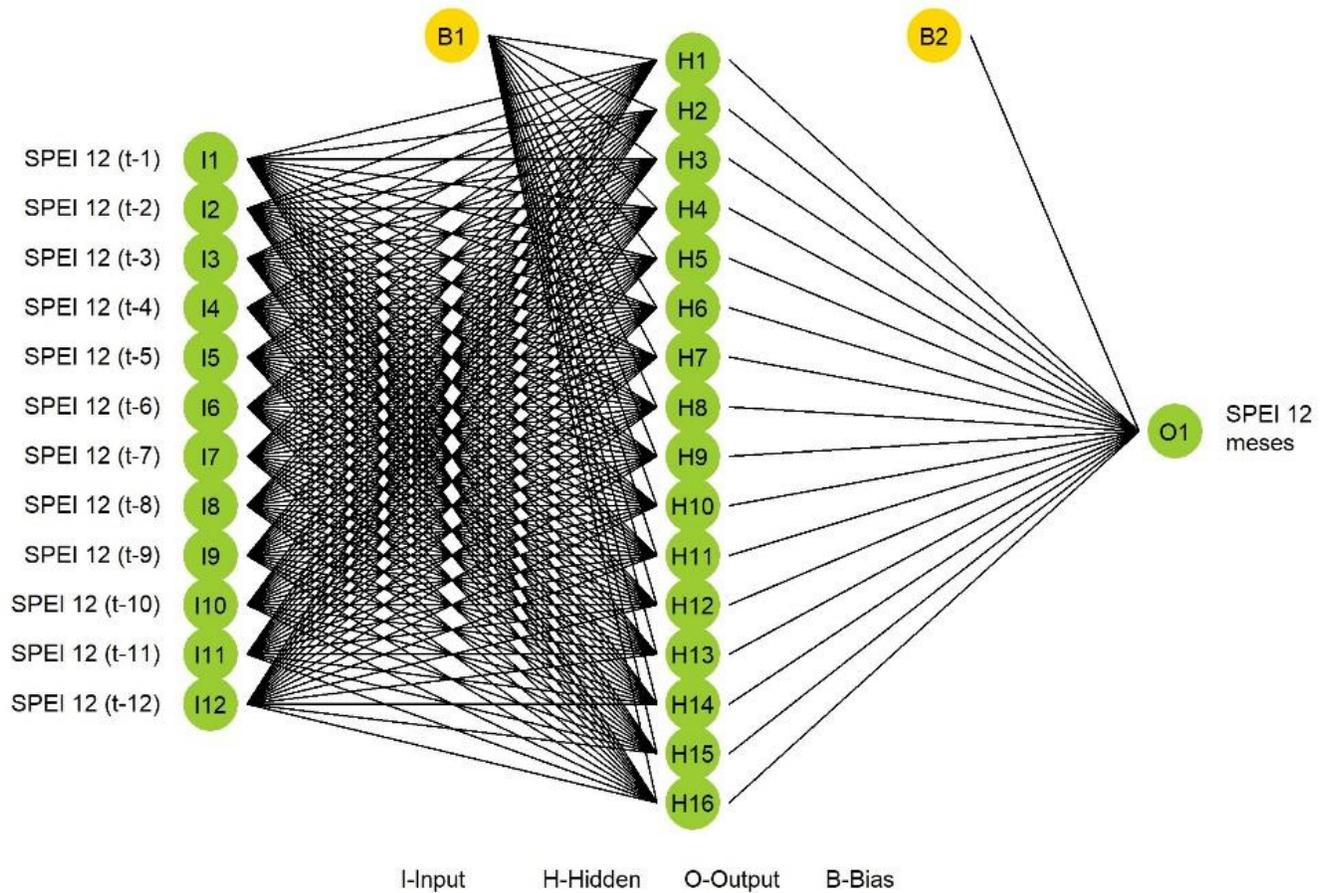
**Tabla 6.** Modelos óptimos de redes neuronales para el grupo 3.

Índice	Arquitectura óptima	Algoritmo de entrenamiento	Entrenamiento			Validación			Serie completa		
			<i>MSE</i>	<i>E</i>	$R^2$	<i>MSE</i>	<i>E</i>	$R^2$	<i>MSE</i>	<i>E</i>	$R^2$
SPI 3	7-8-1	<i>RPROP+</i>	0.009	0.62	0.62	0.005	0.70	0.71	0.272	0.63	0.63

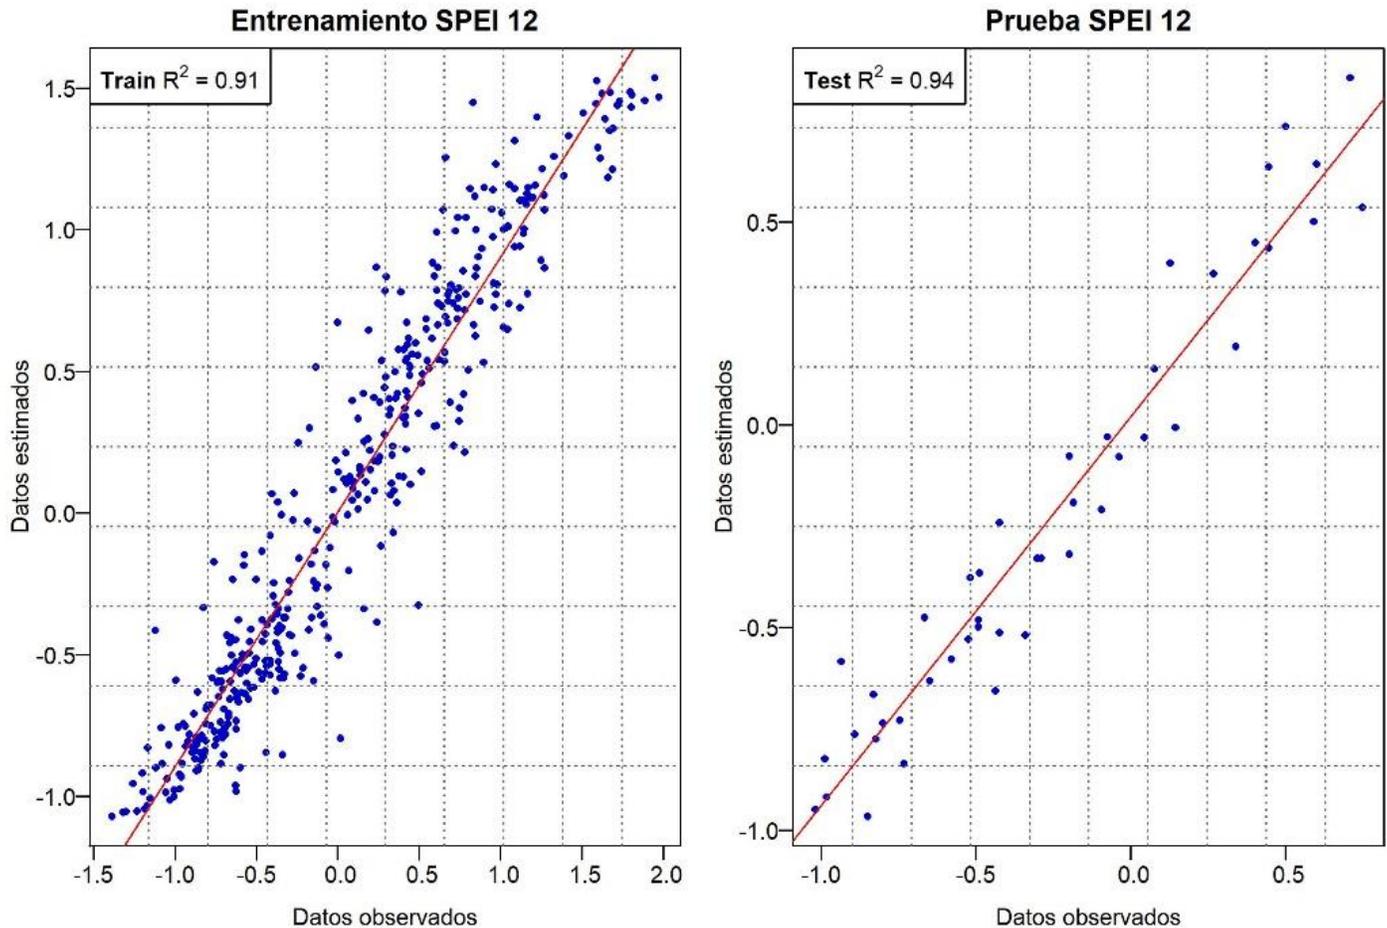
SPI 6	12-17-1	<i>RPROP-</i>	0.006	0.87	0.87	0.003	0.83	0.83	0.100	0.87	0.87
SPI 12	12-15-1	<i>RPROP-</i>	0.004	0.91	0.91	0.002	0.87	0.88	0.070	0.90	0.90
SPI 24	7-15-1	<i>RPROP+</i>	0.002	0.96	0.96	0.001	0.90	0.90	0.033	0.96	0.96
SPEI 3	8-10-1	<i>RPROP+</i>	0.010	0.79	0.79	0.008	0.49	0.62	0.135	0.79	0.79
SPEI 6	12-19-1	<i>RPROP+</i>	0.004	0.90	0.90	0.003	0.90	0.90	0.060	0.90	0.90
SPEI 12	12-16-1	<i>RPROP+</i>	0.005	0.91	0.91	0.002	0.93	0.94	0.048	0.91	0.91
SPEI 24	5-10-1	<i>RPROP-</i>	0.002	0.96	0.96	0.001	0.77	0.80	0.020	0.96	0.96

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.

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; la capa oculta tiene una densidad de 16 neuronas.



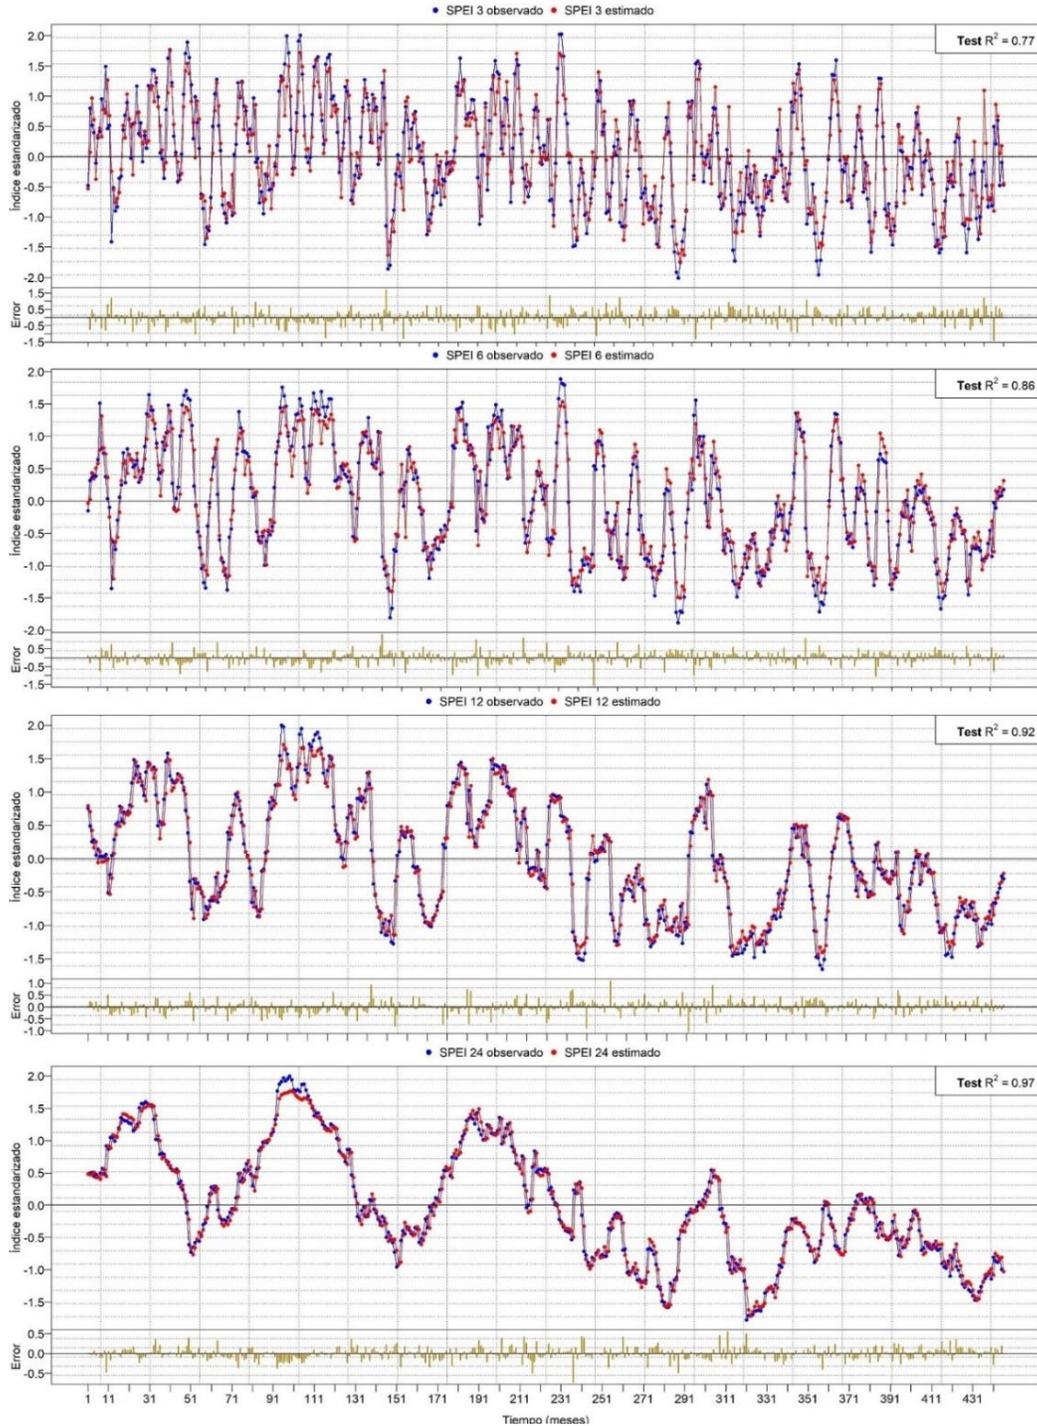
**Figura 8.** Arquitectura de la red neuronal para SPEI 12 del grupo 3.



**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 el que 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 del SPI y del SPEI, 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 se reportaron 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 Comisión

Nacional del Agua (Conagua) y el SMN (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										

## 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 hidrológicas 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 e 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.

### **Agradecimientos**

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

### **Referencias**

- 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. Recuperado de <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. Recuperado de <https://doi.org/10.1007/s11069-019-03665-6>
- ASCE, American Society of Civil Engineers. (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). Recuperado de <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. Recuperado de <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). Recuperado de <http://sac.csic.es/spei>
- Campos-Aranda, D. F. (1998). *Procesos del ciclo hidrológico* (3a ed.). San Luis Potosí, México: 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. Recuperado de [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. Recuperado de <https://doi.org/10.20937/ATM.2016.29.02.02>
- Conagua & SMN, Comisión Nacional del Agua & Servicio Meteorológico Nacional. (2020). *Monitor de Sequía de México (MSM)*. Recuperado

de <https://smn.conagua.gob.mx/es/climatologia/monitor-de-sequia/monitor-de-sequia-en-mexico>

Djebouai, 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. Recuperado de <https://doi.org/10.1007/s11269-016-1298-6>

El-Ibrahimi, 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. Recuperado de <https://doi.org/10.22266/ijies2018.0228.28>

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. Recuperado de <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. Recuperado de <https://doi.org/10.14350/rig.59837>

- Günther, F., & Fritsch, S. (2010). Neuralnet: Training of neural networks. *R Journal*, 2(1), 30-38. Recuperado de <https://doi.org/10.32614/rj-2010-006>
- Haykin, S. (1998). *Neural networks: A comprehensive foundation* (2<sup>nd</sup> ed.). Ontario, Canadá: 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*. Recuperado de <https://doi.org/https://doi.org/10.20937/ATM.52954>
- 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. Recuperado de <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. Recuperado de <https://doi.org/10.1007/s40808-019-00647-2>
- Martín-del-Brio, B., & Sanz-Molina, A. (2001). *Redes neuronales y sistemas difusos*. Bogotá, Colombia: Alfaomega.
- McCulloch, W. S., & Pitts, W. (1943). A logic calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115-133. Recuperado de <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. Recuperado de <https://doi.org/10.1016/j.ecolmodel.2006.04.017>
- Mishra, A. K., & Singh, V. P. (2011). Drought modeling - A review. *Journal of Hydrology*, 403(1-2), 157-175. Recuperado de <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. Recuperado de <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. Recuperado de <https://doi.org/10.3390/w10111564>
- OMM, Organización Meteorológica Mundial. (2011). Guía de prácticas climatológicas. Vol. 100. Ginebra, Suiza: Organización Meteorológica Mundial.

- OMM & GWP, Organización Meteorológica Mundial & Asociación Mundial para el Agua. (2016). Manual de indicadores e índices de sequía. En: *Programa de gestión integrada de sequías. Serie 2 de herramientas y directrices para la gestión integrada de sequías*. Ginebra/Estocolmo, Suiza: Organización Meteorológica Mundial y Asociación Mundial para el Agua.
- Ortíz, D., Villa, F., & Velásquez, J. (2007). A comparison between evolutionary strategies and RPROP for estimating neural networks. *Avances e 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. Recuperado de [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001114](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001114)
- Poomima, 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. Recuperado de <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* (pp. 29-34). Recuperado de <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. Recuperado de <https://doi.org/10.1007/s00704-012-0592-3>
- Riedmiller, M. (1994). Advanced supervised learning in multi-layer perceptron's - 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)* (pp. 586-591). Recuperado de <https://doi.org/10.1109/icnn.1993.298623>
- RStudio. (2018). *RStudio: Integrated Development Environment for R*. RStudio, Inc. Recuperado de <http://www.rstudio.com/>
- SMN, Servicio Meteorológico Nacional. (2019). *Red de Estaciones Climatológicas. Climatología mensual*. Ciudad de México, México: Servicio Meteorológico Nacional. Recuperado de <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. Recuperado de <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. Recuperado de <https://doi.org/10.5154/r.inagbi.2015.03.002>
- Velásquez, J. D., Fonnegra, Y., & Villa, F. A. (2013). Pronóstico de series de tiempo con redes neuronales regularizadas y validación cruzada. *Revista Vínculos*, 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. Recuperado de <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. Recuperado de <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. Recuperado de <https://doi.org/10.1016/j.scitotenv.2019.01.431>