



UNIVERSIDAD AUTÓNOMA CHAPINGO

POSGRADO EN INGENIERÍA AGRÍCOLA Y USO
INTEGRAL DEL AGUA

**ANÁLISIS ESPACIOTEMPORAL DE LA
SEQUÍA CON SPEI EN EL ESTADO DE
MÉXICO Y CIUDAD DE MÉXICO
TESIS DE GRADO**

Que como requisito parcial para obtener el grado de:

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




Presenta:

MAURICIO CARRILLO CARRILLO

Bajo la supervisión de:
DRA. LAURA ALICIA IBÁÑEZ CASTILLO



Chapingo, Estado de México, 8 de septiembre de 2025



ANÁLISIS ESPACIOTEMPORAL DE LA SEQUÍA CON SPEI EN EL ESTADO
DE MÉXICO Y CIUDAD DE MÉXICO

Tesis realizada por el **M.C. MAURICIO CARRILLO CARRILLO** 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. GUSTAVO ANTONIO ARÉVALO GALARZA

LECTOR EXTERNO:

DR. ABEL QUEVEDO NOLASCO

CONTENIDO

RESUMEN GENERAL	1
GENERAL ABSTRACT	2
1 INTRODUCCIÓN GENERAL	3
1.1 Literatura citada	6
2 REVISIÓN DE LITERATURA	10
2.1 Tipos y monitoreo de sequía	10
2.1.1 Definición de sequía	10
2.1.2 Clasificación actualizada de tipos de sequía	10
2.1.3 Importancia del monitoreo de sequías	11
2.2 Índices de sequía	12
2.2.1 Índice SPI (Standardized Precipitation Index)	12
2.2.2 Índice SPEI (Standardized Precipitation Evapotranspiration Index)	13
2.2.3 Índice PDSI (Palmer Drought Severity Index)	14
2.2.4 Otros índices modernos	14
2.2.5 Comparación de índices y su aplicabilidad	15
2.3 SPEI y su importancia	16
2.3.1 Aplicaciones regionales y continentales	16
2.3.2 Aplicaciones sectoriales	17
2.3.3 SPEI y cambio climático	17
2.4 Evapotranspiración mediante el método de Hargreaves	18
2.4.1 Métodos de estimación de la ETP	18
2.4.2 Comparación y aplicaciones recientes	19
2.4.3 Limitaciones	19
2.5 Modelos predictivos aplicados a sequías	19
2.5.1 Modelos estadísticos	20
2.5.2 Modelos basados en redes neuronales artificiales	20
2.5.3 Modelos híbridos y sistemas de aprendizaje automático	21
2.5.4 Modelos de filtros bayesianos (Kalman, partículas)	21

2.5.5	Desafíos actuales	22
2.6	Clasificación de modelos: estadísticos vs. inteligentes	22
2.6.1	Modelos estadísticos	22
2.6.2	Modelos inteligentes (IA y ML).....	23
2.6.3	Hacia enfoques híbridos	24
2.7	Índices climáticos para el monitoreo de sequías (SPI, SPEI, PDSI, etc.).....	24
2.7.1	Índice de Precipitación Estandarizado (SPI).....	25
2.7.2	Índice de Precipitación-Evapotranspiración Estandarizado (SPEI)	25
2.7.3	Índice de Severidad de Sequía de Palmer (PDSI)	26
2.7.4	Otros índices relevantes	26
2.7.5	Aplicación en sistemas de alerta temprana	26
2.8	Aplicaciones del SPEI a nivel mundial y nacional.....	27
2.8.1	Aplicaciones a nivel mundial.....	27
2.8.2	Aplicaciones en América Latina	28
2.8.3	Aplicaciones en México	28
2.8.4	Ventajas operativas del SPEI	29
2.9	Evapotranspiración y método de Hargreaves	29
2.9.1	Evapotranspiración potencial (ETP)	29
2.9.2	Métodos para estimar ETP	30
2.9.3	Método de Hargreaves	30
2.9.4	Ventajas del método de Hargreaves	31
2.9.5	Limitaciones	31
2.10	Modelos de predicción de sequías	32
2.10.1	Importancia del modelado predictivo	32
2.10.2	Tipos de modelos utilizados.....	33
2.10.3	Datos y variables comunes en los modelos	34
2.10.4	Horizonte de predicción y escalas temporales.....	35
2.11	Clasificación de modelos: estadísticos vs. inteligentes	35
2.11.1	Modelos estadísticos	36
2.11.2	Modelos inteligentes (inteligencia artificial).....	37

2.12	Filtro de Kalman con variables exógenas (FK, DKF-ARX-Pt)	38
2.12.1	Fundamentos teóricos	38
2.12.2	Filtro de Kalman dual con modelos ARX (DKF-ARX-Pt)	39
2.12.3	Ventajas comparativas frente a otros modelos	40
2.12.4	Limitaciones y desafíos	41
2.13	Unidades Recurrentes Cerradas (GRU)	41
2.13.1	Fundamentos de las redes neuronales recurrentes (RNN)	42
2.13.2	Evolución hacia GRU	42
2.13.3	Aplicaciones de GRU en predicción de sequías	43
2.13.4	Consideraciones para su implementación	43
2.14	Redes Neuronales NARX (Nonlinear AutoRegressive with eXogenous inputs) 44	
2.14.1	Estructura del Modelo NARX	44
2.14.2	Implementaciones Exitosas en Sequía	45
2.15	Literatura Citada.....	46
3	SPATIO-TEMPORAL ANALYSIS OF DROUGHT WITH SPEI IN THE STATE OF MEXICO AND MEXICO CITY	51
3.1	Abstract.....	52
3.2	Resumen.....	53
3.3	Introduction	53
3.4	Material and Methods.....	56
3.4.1	Description of the Study Area	56
3.4.2	Climatological Databases	57
3.4.3	Climatol: Software for the Validation and Analysis of Climate Data	58
3.4.4	Mann–Kendall Statistical Test	58
3.4.5	Climate Engine	59
3.4.6	CHIRPS Satellite Data.....	60
3.4.7	DAYMET Satellite Data.....	61
3.4.8	Potential Evapotranspiration Equations (PETs).....	61
3.4.9	Drought Indices	62

3.5	Results	65
3.6	Discussion.....	72
3.7	Conclusions.....	73
3.8	References.....	75
4	SPEI DROUGHT FORECASTING IN CENTRAL MEXICO	80
4.1	Abstract.....	81
4.2	Resumen.....	82
4.3	Introduction	83
4.4	Materials and Methods	85
4.4.1	Description of the study area	85
4.4.2	Climatological data	86
4.4.3	CHIRPS satellite information	88
4.4.4	DAYMET satellite data.....	88
4.4.5	Standardized Precipitation Evapotranspiration Index (SPEI)	89
4.4.6	Selection of representative weather stations.....	90
4.4.7	Drought forecasting	93
4.4.8	Model Selection.....	94
4.4.9	Kalman Filter with Exogenous Variables (DKF-ARX-Pt).....	95
4.4.10	Gated Recurring Units (GRU).....	95
4.4.11	Autoregressive Neural Networks with External Input (NARX)	96
4.4.12	Prediction Model Evaluation Metrics	96
4.4.13	Model Training and Forecasting.....	97
4.5	Results	100
4.6	Discussion.....	110
4.7	Conclusions.....	113
4.8	References.....	114
5	CONCLUSIÓN GENERAL.....	121

ÍNDICE DE TABLAS

CAPITULO 2. REVISIÓN DE LITERATURA

<i>Tabla 1. Comparación de distintos índices y variables usadas.</i>	<i>15</i>
<i>Tabla 2. Métodos para estimación de ETP y datos requeridos.</i>	<i>30</i>

CAPITULO 3. SPATIO-TEMPORAL ANALYSIS OF DROUGHT WITH SPEI IN THE STATE OF MEXICO AND MEXICO CITY

<i>Table 1. SPEI categories and classification (McKee, Doesken & Kleist, 1993).</i>	<i>65</i>
<i>Table 2. SPEI categories and classification (McKee et al., 1993).</i>	<i>89</i>
<i>Table 3. An example of the classification of stations with their respective Z-values and assigned weather patterns.</i>	<i>91</i>
<i>Table 4. Main parameters used for each forecasting model.</i>	<i>101</i>
<i>Table 5. Average training time per model (per station) using Intel Core i7, 16 GB RAM.</i>	<i>102</i>
<i>Table 6. Summary of the averages of each metric for the three models</i>	<i>102</i>
<i>Table 7. Paired tests (t-test and Wilcoxon) between pairs of models for each metric and horizon ($\alpha = 0.05$).</i>	<i>103</i>
<i>Table 8. Average metrics of the 23 stations analyzed for a 3-month prediction with SPEI24.</i>	<i>110</i>
<i>Table 9. Performance comparison by model for 3-month forecasting (averages over 23 stations)</i>	<i>110</i>

ÍNDICE DE FIGURAS

CAPITULO 3. SPATIO-TEMPORAL ANALYSIS OF DROUGHT WITH SPEI IN THE STATE OF MEXICO AND MEXICO CITY

Figure 1. Location of the State of Mexico, Mexico City, and the 381 weather stations operated by the SMN 57

Figure 2. Quality, singularity, and location of the 381 stations obtained from Climatol each different symbols represents a different station. 66

Figure 3. Trends in the variables analyzed in the study area (TSC = significant increasing trend; TSD = significant decreasing trend; TNSC = non-significant increasing trend; TNSD = non-significant decreasing trend). 68

Figure 4. Spatial distribution of maximum and minimum SPEI values calculated for a 3-month time scale (2010–2023). 70

Figure 5. The most severe six-month drought indices in Mexico City and the State of Mexico from 2016 to 2023. 71

Figure 6. Temporal variation of the 6-month SPEI index comparing a station in the west (Valle de Bravo) with a station in the east (Texcoco) of the State of Mexico. 72

CAPITULO 4. SPEI DROUGHT FORECASTING IN CENTRAL MEXICO

Figure 7. Location of the State of Mexico, Mexico City, and the 23 weather stations operated by the SMN. 86

Figure 8. Flowchart of the modeling framework used for SPEI drought forecasting. It summarizes the process from input data preparation, model training (FK, GRU, and NARX), SPEI prediction generation at multiple time scales, and evaluation using statistical metrics and uncertainty analysis. 98

Figure 9. Spatial distribution of values of SPEI calculated for a 3-month time scale (2023): (a) evolution of 3-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural autoregressive networks with external input (NARX) SPEI

values for October; (b) evolution of 3-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural autoregressive networks with external input (NARX) SPEI values for November; (c) evolution of 3-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural auto-regressive networks with external input (NARX) SPEI values for December.

105

Figure 10. Comparison of SPEI 3 values observed and predicted by FK, GRU and NARX models at Chapingo station (ID 15170), including 95% uncertainty bands for FK and GRU.

107

Figure 11. Spatial distribution of values of SPEI calculated for 24-month time scale (2023): (a) evolution of 24-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural autoregressive networks with external input (NARX) SPEI values for October; (b) evolution of 24-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural autoregressive networks with external input (NARX) SPEI values for November; (c) evolution of 24-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural autoregressive networks with External Input (NARX) SPEI values for December.

109

Lista de siglas y acrónimos

Acrónimo	Significado (Español – Inglés)
ANN	Red Neuronal Artificial (Artificial Neural Network)
CDI	Índice Compuesto de Sequía (Composite Drought Index)
CONAGUA	Comisión Nacional del Agua (México)
DKF-ARX-Pt	Filtro de Kalman Dual con variables exógenas y ajuste de parámetros (Dual Kalman Filter with AutoRegressive eXogenous variables and Parameter tuning)
EDDI	Índice de Sequía por Demanda Evaporativa (Evaporative Demand Drought Index)
ENSO	El Niño–Oscilación del Sur (El Niño Southern Oscillation)
FAO	Organización de las Naciones Unidas para la Alimentación y la Agricultura (Food and Agriculture Organization)
FK	Filtro de Kalman (Kalman Filter)
GRU	Unidad Recurrente Cerrada (Gated Recurrent Unit)
IPCC	Panel Intergubernamental sobre Cambio Climático (Intergovernmental Panel on Climate Change)
JRC	Centro Común de Investigación de la Comisión Europea (Joint Research Centre)
KNN	K Vecinos más Cercanos (K-Nearest Neighbors)
LSTM	Memoria a Corto y Largo Plazo (Long Short-Term Memory)
NARX	Modelo Autorregresivo No Lineal con Entradas Exógenas (Nonlinear AutoRegressive with eXogenous inputs)
NDVI	Índice de Vegetación de Diferencia Normalizada (Normalized Difference Vegetation Index)
PDSI	Índice de Severidad de Sequía de Palmer (Palmer Drought Severity Index)

RCP 4.5 / 8.5	Trayectorias de Concentración Representativa (Representative Concentration Pathways)
RNN	Red Neuronal Recurrente (Recurrent Neural Network)
SMN	Servicio Meteorológico Nacional (México)
SPI	Índice de Precipitación Estandarizado (Standardized Precipitation Index)
SPEI	Índice de Precipitación-Evapotranspiración Estandarizado (Standardized Precipitation-Evapotranspiration Index)
SSI	Índice Estandarizado de Humedad del Suelo (Standardized Soil Moisture Index)
SVM	Máquina de Vectores de Soporte (Support Vector Machine)
TBATS	Modelo estocástico para series temporales complejas (Trigonometric Box-Cox ARMA Trend Seasonal model)
VCI	Índice de Condición de Vegetación (Vegetation Condition Index)

A mi *Familia*, a mi amado *Sol*, a mis *Hijos*.

A los futuros lectores, esperando haber hecho una diferencia en su mundo.

Carpe diem, quam minimum credula postero. Horacio (Odas, I, 11).

“Aprovecha el día, confía lo menos posible en el mañana.

Agradecimientos

Al Consejo Nacional de Humanidades, Ciencia y Tecnología, CONAHCYT, de México por el apoyo financiero prestado en forma de beca manutención de posgrado para el desarrollo de esta investigación.

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

A la Dra. Laura Alicia Ibáñez Castillo por creer desde el principio en este proyecto de investigación y guiarme para consolidarlo compartiéndome su experiencia.

Al Dr. Ramón Arteaga Ramírez por su tiempo brindado, observaciones y recomendaciones que alimentaron este proyecto desde el principio hasta su consolidación.

Al Dr. Gustavo A. Arévalo Galarza por el apoyo brindado, tiempo y sugerencias que dieron lugar a un proyecto final bien estructurado.

A mis profesores y compañeros de generación que desde el primer día me compartieron su amistad y apoyo para poder llegar a este punto del objetivo, de plasmar un tema de investigación.

DATOS BIOGRÁFICOS



Datos personales

Nombre	Mauricio Carrillo Carrillo
Fecha de nacimiento	10 de septiembre de 1984
Lugar de nacimiento	Texcoco de Mora, Estado de México
No. Cartilla militar	C-7040511
CURP	CACM840910HMCRRR01
Licenciatura:	Ingeniero en Irrigación
Cédula profesional	6011881
Maestría	Maestría en Hidrociencias
Cédula profesional	12878391

Desarrollo académico

Bachillerato:	Preparatoria Agrícola, Universidad Autónoma Chapingo
Licenciatura:	Departamento de Irrigación, Universidad Autónoma Chapingo
Maestría:	Hidrociencias, Colegio de Postgraduados

RESUMEN GENERAL

ANÁLISIS ESPACIOTEMPORAL DE LA SEQUÍA CON SPEI EN EL ESTADO DE MÉXICO Y CIUDAD DE MÉXICO

El cambio climático y la creciente demanda de agua están agravando los problemas de abastecimiento en la Ciudad de México y el Estado de México. La escasez de datos meteorológicos completos complica el análisis de fenómenos como las sequías. Para abordar esta limitación, se utilizaron datos climáticos históricos de Climate Engine (1981–2023) para calcular el índice SPEI a diferentes escalas temporales (1 a 24 meses). Los análisis estadísticos revelaron mayor homogeneidad en los datos de temperatura que en los de precipitación. La prueba de Mann–Kendall mostró un aumento significativo en la temperatura, pero no en la precipitación. Las sequías se han intensificado en la última década, con mayor frecuencia en el oeste del Estado de México y el suroeste de la Ciudad de México, especialmente en 2017, 2019, 2020, 2021 y 2023. El estudio comparó tres modelos de predicción del SPEI: el Filtro de Kalman con variables exógenas (DKF-ARX-Pt), redes neuronales GRU y redes NARX. La evaluación se basó en métricas como MAE, MSE, RMSE, R^2 , NSE y KGE. El modelo DKF-ARX-Pt fue el más preciso y estable en todas las escalas, mientras que las redes GRU tuvieron un desempeño aceptable en escalas largas (SPEI12 y SPEI24), pero inestable en escalas cortas. Las redes NARX presentaron el peor desempeño, con altos errores y baja eficiencia. Se concluye que los modelos basados en filtros de Kalman son herramientas eficaces para predecir condiciones de sequía y apoyar la gestión hídrica en regiones vulnerables.

Palabras clave: Índice de sequía, filtro de Kalman, SPEI, CHIRPS, DAYMET

Tesis de Doctorado en Ingeniería

Doctorado, Programa Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Autor: Mauricio Carrillo Carrillo

Director de Tesis: Dra. Laura A. Ibáñez Castillo

GENERAL ABSTRACT

SPATIAL-TEMPORAL ANALYSIS OF DROUGHT USING SPEI IN THE STATE OF MEXICO AND MEXICO CITY

Climate change and the growing demand for water are aggravating water supply problems in Mexico City and the State of Mexico. The scarcity of comprehensive meteorological data complicates the analysis of phenomena such as droughts. To address this limitation, historical climate data from Climate Engine (1981-2023) were used to calculate the SPEI index at different time scales (1 to 24 months). Statistical analyses revealed greater homogeneity in temperature data than in precipitation data. The Mann-Kendall test showed a significant increase in temperature, but not in precipitation. Droughts have intensified in the last decade, with greater frequency in western Mexico State and southwestern Mexico City, especially in 2017, 2019, 2020, 2021, and 2023. The study compared three SPEI prediction models: the Kalman Filter with exogenous variables (DKF-ARX-Pt), GRU neural networks and NARX networks. The evaluation was based on metrics such as MAE, MSE, RMSE, R^2 , NSE and KGE. The DKF-ARX-Pt model was the most accurate and stable at all scales, while the GRU networks performed acceptably at long scales (SPEI12 and SPEI24), but unstable at short scales. NARX networks presented the worst performance, with high errors and low efficiency. It is concluded that Kalman filter-based models are effective tools to predict drought conditions and support water management in vulnerable regions.

Key words: Drought index, Kalman filter, SPEI, CHIRPS, DAYMET.

Thesis, Doctorado en Ingeniería

Doctorado, Programa Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo

Author: Mauricio Carrillo Carrillo

Advisor: Dra. Laura A. Ibáñez Castillo

1 INTRODUCCIÓN GENERAL

El agua es un recurso estratégico para el desarrollo económico, social y ambiental de cualquier región. En particular, la Zona Metropolitana del Valle de México enfrenta una creciente presión sobre sus fuentes de abastecimiento debido a la urbanización acelerada, el crecimiento poblacional y la intensificación de los efectos del cambio climático (OCDE, 2021; CONAGUA, 2023; Vargas-Morales et al., 2023). Estas condiciones han derivado en una mayor frecuencia de fenómenos hidrometeorológicos extremos, como las sequías, que afectan la disponibilidad de agua tanto para consumo humano como para actividades productivas esenciales, como la agricultura y la industria (IPCC, 2021; López-Moreno et al., 2020).

La sequía, entendida como un déficit prolongado en el suministro de agua respecto a condiciones normales, se manifiesta en diferentes formas: meteorológica, agrícola, hidrológica y socioeconómica. Cada una de estas dimensiones implica afectaciones diferenciadas, desde la reducción de precipitaciones y humedad del suelo hasta impactos en cultivos, caudales y sistemas económicos dependientes del agua (Wilhite & Glantz, 1985; Mishra & Singh, 2010). En este contexto, las sequías se configuran como un fenómeno multifactorial, cuyas consecuencias se amplifican por la vulnerabilidad estructural de los territorios expuestos (Domínguez-Castro et al., 2019; Magaña & Conde, 2000).

En la región centro del país, especialmente en el Estado de México y la Ciudad de México, los eventos de sequía han aumentado en intensidad y frecuencia en las últimas décadas (Martínez-Austria & Patiño-Gómez, 2012). La disminución en la recarga de acuíferos, la reducción del volumen útil de presas como las del Sistema Cutzamala, y la disminución de la precipitación efectiva durante las temporadas críticas, han puesto en evidencia la necesidad de fortalecer los mecanismos de monitoreo y predicción de este tipo de fenómenos (Martínez-Austria & Patiño-Gómez, 2012; INEGI, 2020). Este problema no solo compromete el abastecimiento de agua potable, sino también la seguridad alimentaria, la

conservación de ecosistemas y la estabilidad de sistemas sociales (López-Moreno et al., 2013; Nieto-Garibay et al., 2021).

Ante este escenario, se vuelve imprescindible contar con herramientas robustas para la caracterización y el análisis predictivo de las sequías. El índice SPEI (Standardized Precipitation Evapotranspiration Index) se ha consolidado como una de las métricas más eficaces para el análisis multiescalar de sequías, al incorporar el balance entre la precipitación y la evapotranspiración potencial (Vicente-Serrano et al., 2010; Beguería et al., 2014). Su sensibilidad al calentamiento global lo hace particularmente útil en contextos donde el incremento de la temperatura incide significativamente en los ciclos hidrológicos (Seneviratne et al., 2010; Zubieta et al., 2019). Además, su adaptabilidad a diferentes escalas temporales permite aplicarlo tanto en el monitoreo operativo como en la planificación de recursos hídricos (Herrera-Estrada & Domínguez, 2018; López-Bernal et al., 2020; Martínez-Fernández et al., 2016).

La generación de pronósticos confiables de sequía constituye un componente esencial de la gestión hídrica anticipada. Sin embargo, los métodos estadísticos tradicionales presentan limitaciones importantes en la detección de patrones no lineales y en la integración de variables exógenas complejas (Razavi et al., 2012). Por ello, han cobrado relevancia los modelos avanzados de predicción como los Filtros de Kalman con variables exógenas (Moradkhani et al., 2005), las Redes Neuronales Recurrentes tipo GRU (Cho et al., 2014), y los modelos NARX (Shrestha et al., 2015). Recientemente, autores como Liu et al. (2020) y Tian et al. (2021) han demostrado que la combinación de modelos híbridos mejora significativamente la precisión de los pronósticos de sequía. Estas metodologías, basadas en aprendizaje automático y filtrado estocástico, ofrecen la posibilidad de capturar la dinámica temporal de la sequía y generar escenarios futuros con mayor precisión, lo que representa un aporte valioso para la toma de decisiones en políticas públicas y manejo adaptativo del recurso hídrico (Srivastava et al., 2014; Dehghani et al., 2021; Wang et al., 2019). En este contexto, el presente trabajo tiene como objetivo realizar una revisión bibliográfica sistemática y detallada sobre el estudio del índice SPEI y la predicción de sequías mediante el

uso del índice SPEI con modelos avanzados como FK, GRU y NARX, con énfasis en su aplicabilidad en regiones críticas como el Valle de México. A través del análisis comparativo de enfoques teóricos y casos de estudio, se busca aportar elementos científicos y técnicos que fortalezcan la resiliencia hídrica regional frente a la creciente variabilidad climática.

Para cumplir con el objetivo de esta investigación, el presente trabajo se organiza en cinco capítulos:

Capítulo 1- Introducción general se presenta la problemática actual en la zona de estudio referente a la crisis hídrica ocasionada por las sequías, intensificadas por el cambio climático, afectando gravemente la seguridad hídrica, la agricultura y la infraestructura, especialmente en regiones urbanas como el Valle de México y la implementación de modelos avanzados para la predicción temprana de sequías.

Capítulo 2- Revisión de literatura se describe aspectos teóricos sobre las sequías se revisa el uso del índice SPEI para el monitoreo multiescalar de sequías y explora modelos predictivos avanzados como el Filtro de Kalman con variables exógenas, GRU y NARX. Se destaca su aplicabilidad en contextos con alta variabilidad climática y limitaciones de datos, con el objetivo de fortalecer la resiliencia hídrica regional.

Capítulo 3- Spatio-temporal analysis of drought with SPEI in the state of Mexico and Mexico City, el cambio climático y la creciente demanda hídrica están agravando los problemas de abastecimiento en la Ciudad de México y el Estado de México. Utilizando datos satelitales de Climate Engine, se calculó el índice SPEI en escalas de 1 a 24 meses entre 1981 y 2023. Los análisis revelan una tendencia significativa al aumento de temperatura y una intensificación reciente de las sequías, especialmente en el oeste del Estado de México y el suroeste de la capital. Estos resultados subrayan la urgencia de fortalecer la gestión del agua y las estrategias de adaptación frente al cambio climático.

Capítulo 4- SPEI Drought Forecasting in Central Mexico, se compara tres modelos predictivos del índice SPEI a distintas escalas temporales: Filtro de Kalman con variables exógenas (FK), redes GRU y redes NARX. Utilizando variables meteorológicas y valores de índices de SPEI del Estado de México y la Ciudad de México, evaluando el desempeño mediante métricas como MAE, RMSE, R^2 , NSE y KGE para obtener el modelo con mayor precisión y estabilidad en todas las escalas, y tener una herramienta eficaz para predecir sequías y apoyar la gestión del agua en zonas vulnerables.

Capítulo 5- Conclusión general se presenta los principales hallazgos de la investigación, destacando el aumento en la intensidad y frecuencia de las sequías en el Estado de México y la Ciudad de México, su relación con el incremento de la temperatura y la utilidad del índice SPEI para su análisis multiescalar. Asimismo, la comparación de modelos predictivos, evidenciando la superioridad del Filtro de Kalman con variables exógenas frente a las redes GRU y NARX, y subraya la importancia de integrar monitoreo multiescalar, datos satelitales y modelos avanzados para fortalecer la gestión hídrica, la planificación adaptativa y la resiliencia ante el cambio climático.

1.1 Literatura citada

- Beguería, S., Vicente-Serrano, S. M., Reig, F., & Latorre, B. (2014). Standardized precipitation evapotranspiration index (SPEI) revisited: Parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. *International Journal of Climatology*, 34(10), 3001–3023. <https://doi.org/10.1002/joc.3887>
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. *arXiv preprint*, arXiv:1406.1078. <https://doi.org/10.48550/arXiv.1406.1078>
- CONAGUA. (2023). Estadísticas del agua en México 2023. Comisión Nacional del Agua. <https://www.gob.mx/conagua>

- Dehghani, M., Azarnivand, A., & Nikoo, M. R. (2021). Hybrid soft computing models for drought forecasting: A review. *Environmental Monitoring and Assessment*, 193(5), 267. <https://doi.org/10.1007/s10661-021-09050-7>
- Domínguez-Castro, F., Bravo-Pérez, N., & Sánchez-Sesma, M. V. (2019). Climate variability and drought in central Mexico. *Climate of the Past*, 15(2), 527–542. <https://doi.org/10.5194/cp-15-527-2019>
- Herrera-Estrada, J. E., & Domínguez, F. (2018). Observed moisture recycling and the role of precipitation in the water cycle over the continental United States. *Journal of Climate*, 31(10), 3845–3866. <https://doi.org/10.1175/JCLI-D-17-0323.1>
- INEGI. (2020). Estadísticas del agua en México y disponibilidad por entidad. Instituto Nacional de Estadística y Geografía. <https://www.inegi.org.mx/>
- IPCC. (2021). Sixth Assessment Report (AR6) – Climate Change 2021: The Physical Science Basis. Intergovernmental Panel on Climate Change. <https://www.ipcc.ch/report/ar6/wg1/>
- Liu, J., Zhang, L., & Gao, H. (2020). Hybrid models for hydrological forecasting: A state-of-the-art review. *Water*, 12(2), 350. <https://doi.org/10.3390/w12020350>
- López-Bernal, S., Vicente-Serrano, S. M., Peña-Gallardo, M., & Luna, M. Y. (2020). Evaluation of drought impacts in Mexico using remote sensing and SPEI. *Agricultural Water Management*, 238, 106201. <https://doi.org/10.1016/j.agwat.2020.106201>
- López-Moreno, J. I., Vicente-Serrano, S. M., Zabalza, J., Beguería, S., Lorenzo-Lacruz, J., Azorin-Molina, C., & Morán-Tejeda, E. (2013). Hydrological response to climate variability at different time scales: A study in the Ebro basin. *Hydrological Sciences Journal*, 58(6), 1206–1224. <https://doi.org/10.1080/02626667.2013.802093>
- López-Moreno, J. I., Vicente-Serrano, S. M., Azorin-Molina, C., Peña-Gallardo, M., & Tomas-Burguera, M. (2020). Global warming and drought evolution in

- Mexico: An observational and modeling analysis. *Science of the Total Environment*, 735, 139546. <https://doi.org/10.1016/j.scitotenv.2020.139546>
- Magaña, V., & Conde, C. (2000). Climate and freshwater resources in northern Mexico: Vulnerability, impacts, and response strategies. *Environmental Monitoring and Assessment*, 61(1), 31–50. <https://doi.org/10.1023/A:1006109014294>
- Martínez-Austria, P., & Patiño-Gómez, C. (2012). The hydrological situation of Mexico and its vulnerability to climate change. *Water International*, 37(5), 586–598. <https://doi.org/10.1080/02508060.2012.706773>
- Martínez-Fernández, J., González-Zamora, A., Sánchez, N., & Gumuzzio, A. (2016). A soil water-based index as a suitable agricultural drought indicator. *Agricultural Water Management*, 168, 85–95. <https://doi.org/10.1016/j.agwat.2016.01.011>
- Mishra, A. 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>
- Moradkhani, H., Hsu, K.-L., Gupta, H. V., & Sorooshian, S. (2005). Uncertainty assessment of hydrologic model states and parameters: Sequential data assimilation using the particle filter. *Water Resources Research*, 41(5). <https://doi.org/10.1029/2004WR003604>
- Nieto-Garibay, A., Espinoza, M. E., & Arellano-González, J. (2021). Impactos de la sequía sobre la seguridad alimentaria y recursos hídricos en México. *Revista Mexicana de Ciencias Agrícolas*, 12(4), 759–772. <https://doi.org/10.29312/remexca.v12i4.2785>
- OCDE. (2021). Revisión de la política del agua en México: Hacia una gestión integrada, sostenible y equitativa del recurso. Organización para la Cooperación y el Desarrollo Económicos. <https://www.oecd.org/>
- Razavi, S., Tolson, B. A., & Burn, D. H. (2012). Review of surrogate modeling in water resources. *Water Resources Research*, 48(7). <https://doi.org/10.1029/2011WR011527>

- Seneviratne, S. I., Luthi, D., Litschi, M., & Schar, C. (2010). Land–atmosphere coupling and climate change in Europe. *Nature*, 443, 205–209. <https://doi.org/10.1038/nature05095>
- Shrestha, D. L., Robertson, D. E., Bennett, J. C., & Wang, Q. J. (2015). Using NARX neural network for streamflow forecasting. *Hydrology and Earth System Sciences*, 19(2), 861–876. <https://doi.org/10.5194/hess-19-861-2015>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(56), 1929–1958. <http://jmlr.org/papers/v15/srivastava14a.html>
- Tian, Y., Xu, Z., & Wang, H. (2021). A hybrid deep learning model for spatiotemporal drought prediction. *Remote Sensing*, 13(9), 1829. <https://doi.org/10.3390/rs13091829>
- 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>
- Wang, W., Li, Y., & Song, S. (2019). Drought prediction based on hybrid models using remote sensing and meteorological data. *Agricultural Water Management*, 223, 105695. <https://doi.org/10.1016/j.agwat.2019.105695>
- Zubieta, R., Lavado, W., Rau, P., & Silva, Y. (2019). Evaluation of satellite-based precipitation products over the Peruvian Andes. *Remote Sensing*, 11(6), 687. <https://doi.org/10.3390/rs11060687>

2 REVISIÓN DE LITERATURA

2.1 Tipos y monitoreo de sequía

2.1.1 Definición de sequía

La sequía representa una anomalía climática caracterizada por una disminución persistente de la precipitación, que puede afectar múltiples sectores como la agricultura, la generación de energía y el abastecimiento de agua (Mishra & Singh, 2011; IPCC, 2022). A diferencia de otros eventos extremos como inundaciones o huracanes, la sequía se desarrolla lentamente y sus impactos pueden extenderse mucho más allá del periodo de precipitación reducida, afectando incluso la seguridad alimentaria, la economía y el medio ambiente (Vicente-Serrano et al., 2020).

Desde el enfoque de la gestión de riesgos, la sequía no solo debe entenderse como un evento físico, sino también como el resultado de la interacción entre una amenaza natural y la vulnerabilidad de un sistema socioecológico (UNDRR, 2022). Esto exige abordajes interdisciplinarios que integren aspectos hidrometeorológicos, sociales, económicos y políticos.

2.1.2 Clasificación actualizada de tipos de sequía

Diversos organismos científicos han establecido una clasificación funcional para entender los distintos tipos de sequía según el sistema afectado y los indicadores que permiten su identificación:

a) Sequía meteorológica

Se define como una reducción anormal de la precipitación en comparación con los registros históricos de una región y estación específica. Es el primer tipo de sequía en manifestarse y suele utilizarse como señal temprana de condiciones anómalas (McKee et al., 1993; Zarei et al., 2022). Su severidad puede amplificarse bajo condiciones de aumento térmico como resultado del cambio climático (Vicente-Serrano et al., 2010).

b) Sequía agrícola

Ocurre cuando el contenido de humedad en el suelo no es suficiente para satisfacer los requerimientos hídricos de los cultivos durante su ciclo fenológico. Depende de variables como tipo de cultivo, características del suelo, uso de tecnologías de riego y temperatura (Wilhite & Pulwarty, 2018). Este tipo de sequía se evalúa mejor mediante índices como el SPEI o mediante modelos agrometeorológicos (Suleiman et al., 2023).

c) Sequía hidrológica

Se presenta cuando se reduce el flujo en los cuerpos de agua superficiales y subterráneos como ríos, lagos, presas y acuíferos. Su manifestación puede tardar meses después del inicio de una sequía meteorológica, y su duración suele ser más prolongada (Tallaksen & Van Lanen, 2004; Mahmoud et al., 2023). Este tipo es especialmente importante para la gestión de agua potable y generación hidroeléctrica.

d) Sequía socioeconómica

Es el resultado del desequilibrio entre la oferta y la demanda de agua, generando impactos en actividades económicas como la agricultura, la energía, el transporte y la salud. Este tipo de sequía incorpora variables sociales, institucionales y económicas, y requiere un enfoque de gobernanza para su evaluación y mitigación (UNDRR, 2022; López-Moreno et al., 2021).

2.1.3 Importancia del monitoreo de sequías

El monitoreo continuo y multiescalar de las sequías es esencial para anticipar impactos y facilitar la toma de decisiones. El desarrollo de herramientas como los índices climáticos (SPEI, SPI, EDDI), junto con bases de datos satelitales como CHIRPS, ERA5 y Daymet, ha mejorado significativamente la capacidad de vigilancia a nivel regional y global (Funk et al., 2015; Thornton et al., 2022).

En los últimos años, se han incorporado tecnologías de inteligencia artificial, sistemas de alerta temprana (Early Warning Systems, EWS), y enfoques basados en sensores remotos y estaciones meteorológicas virtuales, lo cual ha mejorado la precisión espacial y temporal del monitoreo (Martínez et al., 2021; Zarei et al., 2022).

Organismos internacionales como la FAO, WMO y el Programa de las Naciones Unidas para el Medio Ambiente (PNUMA) promueven plataformas interoperables para el seguimiento global de sequías, como GDO (Global Drought Observatory), GDIS y el Sistema Mundial de Información sobre la Sequía (WADIS-MAR).

2.2 Índices de sequía

La caracterización y monitoreo de sequías requiere herramientas cuantitativas capaces de capturar las anomalías en el balance hídrico. Los índices de sequía han sido desarrollados para simplificar esta tarea, convirtiendo variables climáticas crudas (como precipitación o temperatura) en valores normalizados que permiten comparar condiciones entre diferentes regiones y períodos. Estos índices son fundamentales para sistemas de alerta temprana, evaluación de impactos y diseño de políticas públicas (WMO, 2020; Vicente-Serrano et al., 2020).

Los principales índices de sequía pueden agruparse según las variables que consideran, la escala temporal en que operan y la información climática que requieren. A continuación, se presentan los más utilizados en la literatura científica y su evolución hacia métricas más complejas y representativas del cambio climático actual.

2.2.1 Índice SPI (Standardized Precipitation Index)

El SPI, desarrollado por McKee et al. (1993), fue uno de los primeros índices en estandarizar la precipitación acumulada a diferentes escalas temporales (1 a 24 meses), permitiendo identificar tanto sequías meteorológicas como hidrológicas.

Su principal ventaja es que requiere solo datos de precipitación, lo que lo hace aplicable en zonas con información climática limitada.

Sin embargo, su limitación más notable es que no considera la temperatura ni otros factores que afectan la demanda atmosférica de agua, lo cual es especialmente crítico bajo condiciones de calentamiento global (Beguería et al., 2023).

2.2.2 Índice SPEI (Standardized Precipitation Evapotranspiration Index)

El índice SPEI (Índice Estandarizado de Precipitación-Evapotranspiración) fue desarrollado por Vicente-Serrano, Beguería y López-Moreno (2010) con el objetivo de superar las limitaciones del SPI al incorporar la influencia de la temperatura y, por ende, la demanda atmosférica de agua sobre los procesos de sequía. A diferencia de índices más simples que únicamente consideran la precipitación acumulada, el SPEI introduce una evaluación del déficit hídrico como resultado del balance entre la precipitación (P) y la evapotranspiración potencial (ETP).

Este enfoque permite capturar mejor los efectos del calentamiento global, dado que las altas temperaturas incrementan la ETP, incluso si las precipitaciones se mantienen constantes. El cálculo del SPEI utiliza el balance hídrico mensual ($P - ETP$), al que se ajusta una distribución de probabilidad log-logística para permitir su estandarización y comparabilidad en diferentes regiones y periodos temporales (Vicente-Serrano et al., 2010).

Una de las principales ventajas del SPEI es su flexibilidad multiescalar, ya que puede calcularse para distintos horizontes temporales (por ejemplo, 1, 3, 6, 12 o 24 meses), lo cual lo hace útil para el análisis de sequías meteorológicas, agrícolas e hidrológicas, según el intervalo considerado (Beguería et al., 2014). Su adaptabilidad lo ha convertido en uno de los índices más utilizados en estudios climáticos y sistemas de monitoreo operativo.

Sin embargo, el valor del SPEI depende directamente del método seleccionado para estimar la ETP. Entre los métodos comúnmente empleados se encuentran los propuestos por Thornthwaite (1948) y Hargreaves & Samani (1985), siendo este último preferido en áreas donde la disponibilidad de datos climáticos es limitada (Beguería & Vicente-Serrano, 2023).

Estudios recientes también han demostrado la utilidad del SPEI en combinación con modelos de aprendizaje automático, como redes neuronales recurrentes y algoritmos híbridos, para predecir eventos extremos en regiones áridas y semiáridas (Liu et al., 2023; Tian et al., 2021).

2.2.3 Índice PDSI (Palmer Drought Severity Index)

El PDSI fue desarrollado por Palmer en 1965 y se basa en un modelo de balance hídrico que considera la humedad del suelo, la evapotranspiración y la recarga del subsuelo. Aunque ha sido ampliamente utilizado en Estados Unidos, presenta limitaciones en regiones tropicales o con alta variabilidad interanual (Alley, 1984).

Una variante moderna es el self-calibrated PDSI (sc-PDSI), que ajusta sus parámetros automáticamente a la climatología local, mejorando su aplicabilidad en diversas regiones del mundo (van der Schrier et al., 2013).

2.2.4 Otros índices modernos

En los últimos años, han surgido nuevos índices que incorporan datos satelitales, inteligencia artificial y múltiples variables climáticas. Algunos de ellos son:

- EDDI (Evaporative Demand Drought Index): mide la demanda atmosférica de agua y se considera un indicador anticipado de sequías agrícolas (Hobbins et al., 2016).
- NDVI o VCI (Vegetation Condition Index): detectan sequías a través de la respuesta de la vegetación observada por sensores remotos.
- SC-PDSI, ESI (Evaporative Stress Index) y versiones integradas multivariantes (Zarei et al., 2022; NDMC, 2023).

2.2.5 Comparación de índices y su aplicabilidad

Tabla 1. Comparación de distintos índices y variables usadas.

Índice	Variables	Escala temporal	Sensible al cambio climático	Aplicabilidad
SPI	Precipitación	1-24 meses	No	Alta
SPEI	Precipitación, temperatura	1-24 meses	Si	Muy alta
PDSI	Pcp, ET, humedad del suelo	Semanal/mensual	Parcial	Moderada
EDDI	Demanda evaporativa	Diario-semanal	Si	Alta (agrícola)
NDVI/VCI	Vegetación	Semanal	Si	Alta en zonas agrícolas

Cada índice tiene ventajas particulares según el contexto regional, la disponibilidad de datos y el tipo de sequía a analizar (

Tabla 1). En estudios recientes, el SPEI ha sido ampliamente adoptado por su capacidad para captar tanto déficits de precipitación como excesos térmicos, siendo ideal para evaluar el impacto del cambio climático (Vicente-Serrano et al., 2020; Zarei et al., 2022).

En conclusión, la elección del índice adecuado depende del objetivo del estudio, la escala temporal y espacial requerida, y la disponibilidad de datos climáticos. El SPEI, por su flexibilidad y sensibilidad al cambio climático, destaca como una herramienta integral en el análisis y predicción de sequías, especialmente cuando

se integra con enfoques modernos como el aprendizaje automático (Tian et al., 2021; Liu et al., 2023).

2.3 SPEI y su importancia

El índice SPEI (Standardized Precipitation Evapotranspiration Index), desarrollado por Vicente-Serrano et al. (2010), ha sido ampliamente adoptado a nivel internacional como una herramienta robusta para el monitoreo y análisis multiescalar de sequías. Gracias a su capacidad para considerar simultáneamente los déficits de precipitación y la demanda atmosférica de agua (a través de la evapotranspiración potencial), el SPEI ofrece una visión más precisa del impacto del cambio climático sobre el balance hídrico que otros índices univariantes como el SPI.

2.3.1 Aplicaciones regionales y continentales

Numerosos estudios han utilizado el SPEI para evaluar tendencias y patrones espaciales de sequía a gran escala. Por ejemplo:

- En Europa, el SPEI ha sido fundamental para documentar el aumento de sequías severas en regiones mediterráneas durante el siglo XXI, atribuibles al incremento de las temperaturas estivales (Spinoni et al., 2017).
- En Asia Central, el índice ha sido clave para identificar zonas vulnerables a sequías agrícolas recurrentes, permitiendo orientar estrategias de seguridad alimentaria (Yang et al., 2023).
- En África subsahariana, el SPEI ha sido utilizado para vincular eventos de sequía con inseguridad alimentaria y migraciones, especialmente en el Sahel (Mekonnen et al., 2020).
- En Sudamérica, estudios han empleado el SPEI para analizar la intensificación de eventos secos en la Amazonía y el Cono Sur, mostrando

su relación con anomalías en la circulación atmosférica y fenómenos como El Niño (Paredes-Trejo et al., 2021).

2.3.2 Aplicaciones sectoriales

El SPEI también ha sido empleado en diversos sectores sensibles a la variabilidad climática, como:

Agricultura

El índice ha demostrado ser un predictor confiable del rendimiento agrícola en regiones semiáridas, permitiendo anticipar pérdidas en cultivos básicos como maíz, trigo y arroz. En China y la India, su aplicación ha sido validada en modelos agroclimáticos multiescalares (Zhang et al., 2025; Singh et al., 2022).

Recursos hídricos

En cuencas hidrográficas, el SPEI se ha correlacionado con los niveles de caudal y almacenamiento en presas, facilitando la gestión integrada del agua. Por ejemplo, se ha implementado en el monitoreo de la cuenca del Nilo Azul y el Río Grande (Hosseinzadehtalaei et al., 2019).

Ecosistemas forestales

En áreas forestales, el SPEI ha sido útil para predecir estrés hídrico en vegetación, incidencia de incendios forestales y mortalidad arbórea. Su combinación con índices de vegetación derivados de imágenes satelitales ha mejorado la capacidad de detección temprana (Trugman et al., 2018).

2.3.3 SPEI y cambio climático

El carácter multiescalar del SPEI lo convierte en una herramienta esencial para evaluar la persistencia y evolución de las sequías bajo distintos escenarios climáticos. Estudios recientes han proyectado un aumento en la frecuencia e intensidad de sequías SPEI-negativas en regiones como el Mediterráneo,

Australia y el suroeste de Estados Unidos, bajo escenarios RCP 4.5 y RCP 8.5 del IPCC (Naumann et al., 2021).

Asimismo, su capacidad de adaptarse a escalas mensuales, estacionales y anuales lo hace ideal para alimentar sistemas de alerta temprana y modelos predictivos basados en inteligencia artificial o simulaciones hidrológicas acopladas.

2.4 Evapotranspiración mediante el método de Hargreaves

La evapotranspiración (ET) es un proceso fundamental del ciclo hidrológico que representa la pérdida combinada de agua por evaporación desde superficies libres y por transpiración de las plantas. La evapotranspiración potencial (ETP) es una estimación teórica de la cantidad de agua que se perdería si el agua estuviera siempre disponible. Esta variable es clave para el balance hídrico y el cálculo de índices de sequía como el SPEI.

2.4.1 Métodos de estimación de la ETP

Existen varios métodos para estimar la ETP, que varían en complejidad y requisitos de datos. Entre los más comunes se encuentran:

- Penman-Monteith FAO56: método estandarizado por la FAO, considerado el más preciso, pero requiere múltiples variables meteorológicas (Allen et al., 2015).
- Thornthwaite: basado solo en temperatura, pero sensible a la latitud y no considera radiación solar.
- Hargreaves & Samani (1985): es un método empírico más sencillo y eficaz que solo necesita temperatura mínima, máxima y radiación o latitud, por lo que es ideal en regiones con información climática limitada.

2.4.2 Comparación y aplicaciones recientes

Aunque métodos como Penman-Monteith ofrecen mayor precisión, estudios recientes han validado que Hargreaves presenta una alta correlación con estos métodos en condiciones climáticas áridas o cuando se realiza una calibración local (Gong et al., 2017; Simsek et al., 2020).

Por esta razón, el método de Hargreaves se ha incorporado en plataformas de monitoreo global como el Climate Engine y herramientas estadísticas como el paquete SPEI en R, lo que ha permitido su aplicación masiva en análisis históricos y de pronóstico de sequías en países de América Latina, África y Asia (Beguería & Vicente-Serrano, 2023; Climate Engine, 2024).

2.4.3 Limitaciones

Pese a sus ventajas, este método tiende a subestimar la ETP en zonas húmedas y no es sensible a cambios en humedad relativa o velocidad del viento, lo que puede afectar la precisión del SPEI en ciertas condiciones (Trajkovic, 2007). Por ello, su uso debe acompañarse de validaciones locales, sobre todo si se emplea para fines de gestión de recursos hídricos o modelación agrícola.

2.5 Modelos predictivos aplicados a sequías

La predicción de sequías es un componente crucial en la gestión del riesgo climático, ya que permite anticipar eventos extremos y tomar decisiones oportunas para reducir sus impactos. A diferencia del monitoreo, que se enfoca en las condiciones actuales o pasadas, el pronóstico de sequías busca estimar la probabilidad de ocurrencia futura de déficit hídricos, ya sea a corto, mediano o largo plazo (Mishra & Singh, 2011).

Los modelos predictivos aplicados a sequías han evolucionado significativamente en las últimas décadas, abarcando desde métodos estadísticos clásicos hasta sofisticadas técnicas de inteligencia artificial y aprendizaje profundo. A continuación, se describen los enfoques más representativos.

2.5.1 Modelos estadísticos

Los modelos estadísticos se basan en relaciones empíricas entre variables climáticas observadas (precipitación, temperatura, humedad del suelo) y ocurrencia de sequías. Algunos de los más comunes son:

- Modelos autorregresivos (AR, ARIMA, SARIMA): pronostican valores futuros de un índice de sequía (como el SPEI) a partir de su comportamiento pasado.
- Modelos de regresión múltiple: integran variables predictoras exógenas como ENSO, NAO o temperaturas oceánicas.
- Modelos de series temporales estocásticas: como TBATS o Holt-Winters, que permiten representar tendencias y estacionalidades.

Aunque estos modelos tienen la ventaja de ser interpretables y requerir poca capacidad computacional, suelen presentar limitaciones para capturar relaciones no lineales y dinámicas complejas en datos climáticos multivariados (Hasan et al., 2023).

2.5.2 Modelos basados en redes neuronales artificiales

Las redes neuronales artificiales (RNA) permiten modelar relaciones no lineales y patrones complejos, incluso con datos incompletos o ruidosos. En el contexto de sequías, se han aplicado principalmente para predecir valores de índices como el SPEI o SPI, caudales de ríos, o contenido de humedad del suelo. Algunos tipos de RNA utilizados incluyen:

- Redes neuronales feedforward (ANN): útiles para pronósticos univariantes.
- NARX (Nonlinear Autoregressive with Exogenous Inputs): integran memoria temporal y variables externas.
- RNN, LSTM y GRU: redes recurrentes diseñadas para series temporales con memoria de largo plazo.

Estudios recientes han mostrado que las redes recurrentes, especialmente las variantes LSTM y GRU, superan en desempeño a modelos tradicionales, particularmente para escalas de predicción de 3 a 12 meses (Zhang et al., 2025; Melchor et al., 2024).

2.5.3 Modelos híbridos y sistemas de aprendizaje automático

Combinan elementos de diferentes enfoques para aprovechar sus fortalezas. Por ejemplo:

- CEEMD–LSTM: usa descomposición empírica de series temporales antes del entrenamiento con redes LSTM.
- Wavelet–ARIMA–LSTM: modelos secuenciales que combinan series estacionarias con aprendizaje profundo.
- Random Forest, XGBoost, SVM: algoritmos de machine learning aplicados al pronóstico categórico de sequía (evento/no evento).

Estos enfoques han mostrado alta precisión, especialmente cuando se emplean datos multivariantes y se consideran variables climáticas globales como ENSO o índices de vegetación (Farzin et al., 2022; Ding et al., 2022).

2.5.4 Modelos de filtros bayesianos (Kalman, partículas)

El Filtro de Kalman, y sus variantes como el DKF-ARX-Pt, son ampliamente utilizados para estimar estados ocultos del sistema hídrico y actualizar predicciones en tiempo real. Su ventaja es la incorporación de incertidumbre y la capacidad de fusionar observaciones con modelos de sistema dinámico, lo que es útil en ambientes con poca información o alta variabilidad (Gupta et al., 2009; Moradkhani et al., 2005).

2.5.5 Desafíos actuales

Pese al avance metodológico, los modelos de predicción de sequías enfrentan varios desafíos:

- Limitada disponibilidad de datos históricos de alta calidad.
- Incertidumbre en proyecciones climáticas a largo plazo.
- Necesidad de calibración local de modelos.
- Falta de integración de variables sociales, económicas y ecológicas.

El desarrollo de sistemas integrados de pronóstico multiescalar con inteligencia artificial, sensores remotos y datos climáticos globales representa una dirección prometedora para mejorar la precisión y utilidad de las predicciones de sequía (Vicente-Serrano et al., 2020; Agudelo et al., 2025).

2.6 Clasificación de modelos: estadísticos vs. inteligentes

El pronóstico de sequías se puede abordar desde dos grandes enfoques metodológicos: los modelos estadísticos (o clásicos) y los modelos inteligentes (basados en inteligencia artificial y machine learning). Esta clasificación no solo refleja diferencias en los algoritmos utilizados, sino también en la forma de representar la dinámica del sistema climático y la relación entre variables.

2.6.1 Modelos estadísticos

Los modelos estadísticos se basan en principios matemáticos y supuestos probabilísticos sobre la relación entre las variables del sistema. Su objetivo principal es ajustar funciones explícitas que representen el comportamiento de una serie temporal o su relación con otras variables independientes.

Características:

- Requieren datos históricos bien distribuidos.
- Supuestos de linealidad, estacionariedad y normalidad.
- Fáciles de interpretar y calibrar.

- Limitados en la detección de relaciones no lineales o complejas.

Modelos comunes:

- AR, MA, ARIMA, SARIMA: Modelos autorregresivos usados para pronósticos univariantes de series de tiempo (McKee et al., 1993; Hasan et al., 2023).
- Regresión lineal múltiple: Estima sequías a partir de variables climáticas predictoras.
- Modelos estocásticos como Markov o TBATS: Capturan patrones estacionales y de tendencia.

Usados ampliamente para pronosticar índices como el SPI y SPEI, así como caudales de ríos, balances hídricos, o condiciones agroclimáticas.

2.6.2 Modelos inteligentes (IA y ML)

Los modelos inteligentes, en particular los basados en aprendizaje automático (machine learning) y aprendizaje profundo (deep learning), permiten identificar relaciones no lineales y patrones ocultos en grandes volúmenes de datos, sin necesidad de supuestos estadísticos estrictos.

Características:

- Mayor capacidad de generalización.
- Pueden trabajar con datos ruidosos, incompletos o no estructurados.
- Requieren más datos y poder computacional.
- Pueden integrarse con imágenes satelitales, modelos físicos y datos en tiempo real.

Modelos comunes:

- Redes neuronales artificiales (ANN, NARX).
- Redes recurrentes (RNN, LSTM, GRU).
- Árboles de decisión, Random Forest, XGBoost.

- SVM, k-NN, redes bayesianas.

Estos modelos han sido aplicados con éxito en la predicción de sequías en múltiples escalas, utilizando como entrada datos climáticos, de vegetación, humedad del suelo, o índices oceánicos (ENSO, ONI). Han sido integrados en sistemas de alerta temprana y en modelos híbridos para aumentar su precisión (Ding et al., 2022; Agudelo et al., 2025).

2.6.3 Hacia enfoques híbridos

Debido a que ambos enfoques tienen ventajas complementarias, se ha promovido el uso de modelos híbridos, como:

- Combinaciones de ARIMA con LSTM o GRU.
- Preprocesamiento de datos con PCA o wavelets antes de aplicarlos a modelos neuronales.
- Sistemas de pronóstico que combinan filtros bayesianos con aprendizaje automático.

Estos modelos híbridos permiten integrar la capacidad explicativa de los métodos clásicos con la potencia predictiva de los algoritmos inteligentes, logrando una mejora significativa en el pronóstico de eventos extremos (Wu et al., 2021; Zhang et al., 2025).

2.7 Índices climáticos para el monitoreo de sequías (SPI, SPEI, PDSI, etc.)

Los índices climáticos son herramientas cuantitativas fundamentales para el monitoreo y análisis de sequías. Permiten transformar series meteorológicas en indicadores estandarizados que reflejan condiciones húmedas o secas en distintas escalas temporales y espaciales. Su uso facilita la toma de decisiones en gestión hídrica, planificación agrícola y evaluación de impactos del cambio climático (WMO & GWP, 2016).

Entre los más utilizados a nivel internacional destacan el Índice de Precipitación Estandarizado (SPI), el Índice de Precipitación Evapotranspiración Estandarizado (SPEI) y el Índice de Severidad de Sequía de Palmer (PDSI). A continuación, se comparan sus características principales.

2.7.1 Índice de Precipitación Estandarizado (SPI)

Desarrollado por McKee et al. (1993), el SPI se basa únicamente en registros de precipitación. Calcula la desviación estándar de la precipitación acumulada respecto a una distribución de referencia (normal o gamma), lo que permite una interpretación estadística uniforme.

- Ventajas: simple, adaptable a diversas escalas temporales (1 a 24 meses), requiere solo precipitación.
- Limitaciones: no considera el efecto de la temperatura ni de la evaporación potencial.

El SPI es útil para evaluar sequías meteorológicas y es ampliamente recomendado por la Organización Meteorológica Mundial para países con registros pluviométricos extensos pero sin otras variables (WMO (2012). Standardized Precipitation Index User Guide. WMO-No. 1090).

2.7.2 Índice de Precipitación-Evapotranspiración Estandarizado (SPEI)

El SPEI, propuesto por Vicente-Serrano et al. (2010), amplía el enfoque del SPI incorporando el balance entre precipitación y evapotranspiración potencial (ETP). Esto lo hace más sensible al calentamiento global y a condiciones climáticas extremas.

- Ventajas: considera el efecto de la temperatura, útil para evaluar sequías agrícolas, hidrológicas y efectos del cambio climático.
- Limitaciones: depende del método de cálculo de la ETP (Hargreaves, Thornthwaite o Penman-Monteith).

Es especialmente adecuado en contextos de cambio climático, donde las temperaturas elevadas intensifican la evaporación y agravan la sequía.

2.7.3 Índice de Severidad de Sequía de Palmer (PDSI)

El PDSI (Palmer, 1965) fue uno de los primeros índices en utilizar un enfoque de balance hídrico completo, integrando datos de precipitación, temperatura y capacidad de retención del suelo.

- Ventajas: considera la humedad del suelo y tiene alta sensibilidad a déficits hídricos prolongados.
- Limitaciones: requiere múltiples datos, es menos flexible a escalas cortas y es sensible a condiciones edafológicas locales.

El PDSI ha sido ampliamente utilizado en estudios de sequías históricas, particularmente en Estados Unidos, pero su aplicabilidad en regiones tropicales es limitada debido a sus supuestos edafoclimáticos.

2.7.4 Otros índices relevantes

Índice de Condición de la Vegetación (VCI): derivado de imágenes de satélite (NDVI), útil para sequías agrícolas.

Índice Estándar de Humedad del Suelo (SSI): basado en datos modelados o in situ de humedad del suelo.

Índice combinado de sequía (CDI): integra múltiples fuentes (climáticas, remotas, sociales).

2.7.5 Aplicación en sistemas de alerta temprana

Actualmente, plataformas como Climate Engine, NOAA Drought Monitor, y sistemas regionales como el Monitor de Sequía de México (CONAGUA), emplean índices como SPI y SPEI integrados con otros datos (satélite, hidrológicos, agrometeorológicos) para generar alertas y mapas de severidad. Esto permite un

enfoque multiescalar, interinstitucional y más dinámico ante la variabilidad climática.

2.8 Aplicaciones del SPEI a nivel mundial y nacional

El Índice de Precipitación-Evapotranspiración Estandarizado (SPEI) ha demostrado ser una herramienta eficaz y flexible para el análisis de sequías en distintos contextos climáticos, geográficos y socioeconómicos. Gracias a su capacidad para reflejar el impacto combinado de precipitación y temperatura sobre el balance hídrico, el SPEI ha sido aplicado extensamente en investigaciones y sistemas de alerta temprana en todo el mundo.

2.8.1 Aplicaciones a nivel mundial

Desde su introducción por Vicente-Serrano et al. (2010), el SPEI ha sido incorporado en numerosos estudios globales y regionales. Se ha utilizado para:

- Evaluar sequías extremas recientes: como en Europa durante 2015–2018 (Spinoni et al., 2019) o en África subsahariana.
- Estudios de tendencias de largo plazo bajo cambio climático: por ejemplo, en Asia Central, donde se han identificado aumentos significativos en la frecuencia de sequías (Li et al., 2022).
- Evaluación de impactos en agricultura, bosques y recursos hídricos: en Estados Unidos, Canadá, India y Australia, se ha correlacionado el SPEI con rendimientos agrícolas, incendios forestales y caudales (Zhang et al., 2025).

Además, el SPEI ha sido adoptado por instituciones como el Centro Común de Investigación de la Comisión Europea (JRC) para construir mapas globales de sequía a múltiples escalas temporales.

2.8.2 Aplicaciones en América Latina

En países latinoamericanos, el SPEI ha sido empleado para:

- Evaluar la vulnerabilidad hídrica y agrícola en regiones como el noreste de Brasil, el altiplano andino y el norte de México (González-Hidalgo et al., 2018).
- Diseñar estrategias de adaptación al cambio climático basadas en escenarios de proyección futura (SPEI proyectado con modelos climáticos CMIP5/CMIP6).
- Monitorear sequías recientes como las ocurridas en el Cono Sur (Argentina–Uruguay–Paraguay) entre 2020 y 2023.

La ventaja del SPEI multiescalar permite estudiar sequías meteorológicas a corto plazo (SPEI-1 a SPEI-3), así como sequías agrícolas (SPEI-6) o hidrológicas de largo plazo (SPEI-12 a SPEI-24).

2.8.3 Aplicaciones en México

En el contexto nacional, el SPEI ha sido utilizado por instituciones académicas y gubernamentales para:

- Analizar eventos históricos de sequía, como los ocurridos en 1994, 2009, 2011 y 2021.
- Estudios regionales en estados como Chihuahua, Sonora, Zacatecas, Estado de México y Chiapas (Magaña & Neri, 2018).
- Monitoreo mensual oficial, donde el Servicio Meteorológico Nacional (CONAGUA (2023). Monitor de Sequía de México. Servicio Meteorológico Nacional.

<https://smn.conagua.gob.mx/tools/RESOURCES/Monitor/MonitorSeca/>)

utiliza el SPEI como parte del Monitor de Sequía de México, en conjunto con SPI y PDSI.

El SPEI también ha sido integrado con datos de satélite y modelación agroclimática para generar pronósticos y alertas tempranas, fortaleciendo los sistemas de gestión del riesgo de sequía.

2.8.4 Ventajas operativas del SPEI

- Multiescalar y flexible, adecuado para diferentes sectores (agrícola, hidrológico, forestal).
- Sensibilidad al calentamiento global, por incluir la evapotranspiración.
- Adaptabilidad a distintas fuentes de datos: estaciones climáticas, modelos climáticos globales, reanálisis y sensores remotos.

Estas cualidades lo convierten en una herramienta clave en la vigilancia climática y la planificación de medidas de adaptación y mitigación ante la sequía.

2.9 Evapotranspiración y método de Hargreaves

La evapotranspiración (ET) es el proceso combinado de evaporación del agua desde superficies como el suelo y cuerpos de agua, y la transpiración del agua desde las plantas. Es un componente clave del balance hídrico y un factor determinante en la aparición y duración de las sequías, especialmente las agrícolas y ecológicas (Allen et al., 1998).

El cálculo preciso de la evapotranspiración es fundamental para estimar el déficit hídrico y para la elaboración de índices como el SPEI, que incorpora el balance entre la precipitación y la evapotranspiración potencial (ETP).

2.9.1 Evapotranspiración potencial (ETP)

La ETP representa la cantidad de agua que se evaporaría y transpiraría si el agua estuviera disponible en cantidad suficiente. Su cálculo puede hacerse mediante modelos de diferente complejidad, que van desde métodos empíricos hasta enfoques basados en física atmosférica.

2.9.2 Métodos para estimar ETP

Existen múltiples métodos para estimar la ETP (Tabla 2), los cuales difieren en los datos requeridos y su complejidad:

Tabla 2. Métodos para estimación de ETP y datos requeridos.

Método	Requiere datos	Precisión	Aplicabilidad
Penman-Monteith (FAO56)	Temp., humedad, viento, radiación solar	Alta	Universal, estándar de referencia
Thornthwaite	Solo temperatura media mensual	Baja	Climas templados, menos precisión
Hargreaves	Temperatura mínima, máxima y radiación	Media	Buena alternativa cuando hay datos limitados

2.9.3 Método de Hargreaves

El método propuesto por Hargreaves y Samani (1985) es uno de los más utilizados cuando no se dispone de información meteorológica completa. Este método estima la ETP diaria utilizando solo tres variables: temperatura mínima, máxima y la radiación solar extraterrestre (calculada a partir de la latitud y día del año).

El método original de Hargreaves calcula la ETP diaria con la siguiente ecuación 1:

$$ET_0 = 0.0023 \cdot (T_{media} + 17.8) \cdot (T_{max} - T_{min})^{0.5} \cdot R_a \quad (1)$$

Donde:

ET₀: Evapotranspiración de referencia (mm/día)

T_{media} : Temperatura media diaria ($^{\circ}\text{C}$)

T_{max} , T_{min} : Temperaturas máxima y mínima diarias ($^{\circ}\text{C}$)

R_a : Radiación extraterrestre ($\text{MJ}/\text{m}^2/\text{día}$), calculada en función de la latitud y la fecha.

Este método ha demostrado ser una alternativa robusta en zonas áridas y semiáridas, donde la radiación solar domina el proceso evaporativo (Droogers & Allen, 2002). Su simplicidad y bajo requerimiento de datos lo han convertido en el método más utilizado para calcular la ETP en estudios de sequía que emplean el índice SPEI, especialmente en regiones en desarrollo.

2.9.4 Ventajas del método de Hargreaves

- Requiere pocos datos: ideal en regiones con escasas estaciones meteorológicas.
- Facilidad de implementación: puede aplicarse en hojas de cálculo o software climático.
- Buen desempeño: se ha demostrado eficaz en zonas áridas y semiáridas, especialmente en México y América Latina (Droogers & Allen, 2002).

2.9.5 Limitaciones

- Menor precisión en climas húmedos o altamente variables.
- No considera viento, humedad relativa ni cobertura de nubes.
- Puede subestimar o sobreestimar la ETP en ciertas condiciones específicas.

A pesar de estas limitaciones, su balance entre simplicidad y utilidad lo ha consolidado como una de las opciones más utilizadas para calcular ETP en el contexto del SPEI y la evaluación de sequías a gran escala.

2.10 Modelos de predicción de sequías

La predicción de sequías representa un reto crucial para la planificación de recursos hídricos, la seguridad alimentaria y la prevención de desastres. A diferencia del monitoreo, que describe eventos pasados, los modelos de predicción buscan estimar el comportamiento futuro de variables climáticas relevantes (como el SPEI), usando series temporales y relaciones entre múltiples factores. En contextos como México y otros países en desarrollo, esta capacidad predictiva es vital para anticipar impactos y tomar decisiones informadas en sectores agrícolas, urbanos y ambientales (Moradkhani et al., 2005).

2.10.1 Importancia del modelado predictivo

El modelado predictivo permite anticiparse a fenómenos complejos como las sequías, cuya naturaleza multiescalar y multicausal hace que su detección y pronóstico no sea inmediata. Las sequías pueden emerger de forma lenta pero tener consecuencias prolongadas y devastadoras, por lo que contar con herramientas que permitan prever su ocurrencia es clave para el diseño de políticas públicas y estrategias de mitigación (Wilhite et al., 2007).

Beneficios del modelado predictivo:

- Prevención de crisis agrícolas y ganaderas por déficit hídrico.
- Optimización en la operación de embalses y sistemas de riego.
- Planeación estratégica en contextos de cambio climático.
- Implementación de alertas tempranas para comunidades vulnerables.

Además, el cambio climático está alterando los patrones de precipitación y temperatura, lo que incrementa la incertidumbre. En este escenario, los modelos predictivos ayudan a proyectar escenarios futuros con base en tendencias observadas y simulaciones climáticas (IPCC, 2021).

2.10.2 Tipos de modelos utilizados

Los modelos de predicción de sequías pueden clasificarse, principalmente, en tres grandes grupos, cada uno con fortalezas y limitaciones según el contexto de aplicación:

a) Modelos estadísticos tradicionales

Se basan en la identificación de patrones históricos en los datos. Entre los más utilizados están:

- AR, MA, ARIMA y SARIMA: útiles para series estacionarias, capturan tendencias y estacionalidades.
- Modelos de regresión lineal y múltiple: relacionan el índice de sequía con otras variables climáticas o geográficas.
- Modelos de correlación cruzada y análisis espectral: útiles para analizar el impacto de ciclos climáticos como ENSO.

Ventajas: fáciles de implementar, bajo requerimiento computacional.

Desventajas: suponen relaciones lineales, no capturan bien procesos no estacionarios o no lineales (Kouadio et al., 2007).

Ejemplo: Mishra & Singh (2011) usaron cadenas de Markov y redes bayesianas para predecir sequías en cuencas andinas con buenos resultados.

b) Modelos deterministas o basados en simulación física

Simulan los procesos hidrológicos mediante ecuaciones que representan fenómenos físicos: escorrentía, infiltración, evaporación, etc.

Ejemplos: SWAT (Soil and Water Assessment Tool), VIC (Variable Infiltration Capacity).

Ventajas: permiten una interpretación física del sistema.

Desventajas: requieren gran cantidad de datos y calibración compleja; mayor carga computacional.

Se usan principalmente para estudios a cuenca o en gestión de recursos hídricos integrados, más que para predicción pura del SPEI.

c) Modelos de inteligencia artificial y aprendizaje automático

Incluyen técnicas capaces de aprender patrones complejos, incluso en presencia de ruido o datos incompletos:

- Redes Neuronales Artificiales (ANN): útiles para series no lineales.
- RNN, LSTM, GRU: redes con memoria temporal, ideales para datos secuenciales.
- Máquinas de soporte vectorial (SVM), árboles de decisión y random forests.
- Modelos híbridos: como CEEMD–LSTM, Wavelet–ANN, o ARIMA-GRU.

Ventajas: alto poder predictivo, adaptabilidad, trabajan con múltiples variables.

Desventajas: mayor complejidad, necesidad de entrenamiento y validación rigurosa, riesgo de sobreajuste si no se aplican técnicas de regularización.

Ejemplo: Alawsi et al. (2022) desarrollaron un modelo híbrido BiLSTM–Harris Hawk para predecir niveles freáticos y sequías con alta precisión.

2.10.3 Datos y variables comunes en los modelos

Los modelos predictivos para sequías requieren distintas fuentes de datos que pueden ser históricas, satelitales, modeladas o simuladas:

- Datos meteorológicos: precipitación, temperatura, humedad relativa, radiación, viento.
- Evapotranspiración potencial (ETP): calculada vía métodos como Hargreaves o Penman-Monteith.

- Variables exógenas: como ENSO (El Niño), NDVI (índice de vegetación), VCI (índice de condición de vegetación), humedad del suelo, altitud, uso de suelo.
- Índices climáticos: SPI, PDSI, SPEI (como variable objetivo o predictora).

El uso de datos satelitales y reanálisis climáticos (CHIRPS, ERA5, DAYMET, MODIS) ha sido clave para aumentar la cobertura espacial y temporal, especialmente en países con baja densidad de estaciones.

2.10.4 Horizonte de predicción y escalas temporales

El desempeño del modelo varía según el horizonte temporal y la escala de predicción:

- Corto plazo (1–3 meses): modelos ARIMA o redes RNN simples pueden ser suficientes.
- Mediano plazo (3–6 meses): se requieren modelos con memoria como GRU o LSTM.
- Largo plazo (6–12 meses o más): modelos híbridos, redes profundas o integración con escenarios climáticos (CMIP6).

Además, el horizonte de predicción debe empatar con la escala temporal del índice de sequía:

- SPEI-1: predice sequía meteorológica.
- SPEI-3 a SPEI-6: útil para sequía agrícola.
- SPEI-12 a SPEI-24: para análisis hidrológico y de disponibilidad de agua a largo plazo.

2.11 Clasificación de modelos: estadísticos vs. inteligentes

La predicción de sequías se ha beneficiado de la evolución metodológica en los enfoques de modelado. Tradicionalmente, los estudios se han basado en modelos estadísticos que exploran patrones y relaciones lineales. Sin embargo,

el creciente acceso a datos multivariados, la mejora de la capacidad computacional y la creciente disponibilidad de técnicas de aprendizaje automático han permitido el desarrollo de modelos inteligentes que superan muchas de las limitaciones de los enfoques tradicionales.

Ambos enfoques tienen sus fortalezas y aplicaciones particulares dependiendo del contexto, los datos disponibles y los objetivos del análisis. A continuación, se detallan sus fundamentos, características, ventajas, limitaciones y ejemplos concretos.

2.11.1 Modelos estadísticos

Los modelos estadísticos emplean técnicas matemáticas que permiten identificar relaciones lineales y patrones dentro de series temporales. Se fundamentan en supuestos como estacionariedad, linealidad, normalidad y homocedasticidad. Son ampliamente usados cuando las series temporales son estables, con estructura clara de estacionalidad y sin grandes discontinuidades.

Principales técnicas estadísticas:

- Modelos AR, MA, ARMA, ARIMA: Modelan la dependencia temporal de una variable en función de sus propios valores pasados y errores.
- SARIMA: Extiende ARIMA para capturar efectos estacionales.
- Regresiones múltiples: Permiten incorporar varias variables independientes para predecir una variable dependiente (por ejemplo, SPEI).
- Cadenas de Markov: Se emplean para modelar la transición de un estado de sequía a otro.
- Modelos y redes bayesianos: Útiles para incorporar incertidumbre y relaciones probabilísticas entre variables.

Fortalezas:

- Bajo requerimiento computacional.

- Fácil implementación e interpretación.
- Requieren menos datos para el entrenamiento.
- Útiles para pronósticos a corto plazo.

Limitaciones:

- Asumen relaciones lineales entre variables.
- Poca capacidad para capturar interacciones complejas o no estacionarias.
- Menor adaptabilidad ante datos faltantes, ruido o eventos extremos.

Hasan, Dongkai & Al-Shibli (2023) compararon modelos ARIMA y TBATS para predecir SPI y SPEI en Jordania, demostrando que, aunque ARIMA tiene buena precisión en el corto plazo, su desempeño se reduce ante cambios abruptos en el clima.

2.11.2 Modelos inteligentes (inteligencia artificial)

Los modelos inteligentes, también llamados de aprendizaje automático, no dependen de suposiciones rígidas sobre la forma de los datos. Estos algoritmos aprenden directamente de los datos y pueden modelar relaciones complejas, no lineales y de alta dimensión. Se usan ampliamente en climatología, hidrología, agricultura y análisis ambiental.

Principales enfoques:

- Redes Neuronales Artificiales (ANN): Capaces de aprender relaciones complejas. Se componen de capas de neuronas que transforman los datos mediante funciones de activación.
- Redes Recurrentes (RNN) y sus variantes LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Unit): Especializadas en modelar secuencias temporales con memoria de largo plazo.
- Máquinas de Soporte Vectorial (SVM): Modelos de clasificación y regresión robustos, útiles para conjuntos de datos limitados.

- Random Forest y XGBoost: Árboles de decisión en conjunto que ofrecen robustez ante ruido y no requieren normalización.
- Modelos híbridos: Combinan métodos estadísticos y de IA (ej. ARIMA-GRU, Wavelet-LSTM).

Fortalezas:

- Capturan relaciones no lineales y multivariadas.
- Manejan mejores datos faltantes, ruidos o variables altamente correlacionadas.
- Se adaptan a múltiples escalas temporales y espaciales.
- Aumentan la precisión del pronóstico a mediano y largo plazo.

Limitaciones:

- Requieren mayor poder computacional y tiempo de entrenamiento.
- Necesitan más datos históricos de buena calidad.
- Su interpretación puede ser limitada (cajas negras).
- Riesgo de sobreajuste si no se emplean técnicas de validación y regularización.

Magaña & Neri (2018) usaron GRU con datos históricos de temperatura, precipitación y evapotranspiración para predecir SPEI mensual en el norte de México, alcanzando altos niveles de precisión.

Agudelo et al. (2025) propusieron una arquitectura híbrida que integra variables estáticas (uso de suelo, elevación) con series temporales para predecir sequías agrícolas en tiempo real, logrando mejoras respecto a métodos tradicionales.

2.12 Filtro de Kalman con variables exógenas (FK, DKF-ARX-Pt)

2.12.1 Fundamentos teóricos

El Filtro de Kalman es un algoritmo de estimación recursiva diseñado para inferir el estado interno de un sistema dinámico a partir de una serie de mediciones observadas que están afectadas por ruido o incertidumbre. Fue desarrollado por

Rudolf E. Kalman en 1960 y se ha convertido en una herramienta fundamental en el análisis de sistemas lineales y en tiempo discreto (Kalman, 1960).

Este filtro se basa en un enfoque bayesiano de mínimos cuadrados, combinando de manera óptima la información proveniente de un modelo dinámico (predictor) con datos de observación (medidas) para actualizar las estimaciones del sistema. La actualización se realiza mediante dos etapas: una predicción, donde se proyecta el estado del sistema al siguiente paso temporal, y una corrección, donde se ajusta esa predicción utilizando las nuevas observaciones disponibles (Welch & Bishop, 1995).

Una de sus principales ventajas radica en su capacidad para incorporar la incertidumbre tanto del modelo como de las mediciones, permitiendo así una estimación más robusta en contextos con datos incompletos o ruidosos. Este enfoque es particularmente útil en el ámbito hidrológico y climático, donde las variables meteorológicas presentan alta variabilidad temporal y espacial, y los modelos de predicción deben adaptarse constantemente a nuevos datos (Moradkhani et al., 2005; Gupta, Wagener, & Liu, 2009).

2.12.2 Filtro de Kalman dual con modelos ARX (DKF-ARX-Pt)

Una extensión poderosa del filtro de Kalman es el Filtro de Kalman Dual con Modelo Autorregresivo con entradas exógenas (DKF-ARX-Pt). Esta técnica combina el poder adaptativo del Kalman Filter con la flexibilidad de los modelos ARX para modelar sistemas dinámicos donde el estado interno y los parámetros varían en el tiempo.

En el contexto de la predicción de sequías, este modelo se formula como una regresión de tipo:

$$SPEI(t) = \sum_{i=1}^p a_i(t) \cdot SPEI(t - i) + \sum_{j=1}^q b_j(t) \cdot X_j(t - j) + \varepsilon(t)$$

donde:

$a_i(t)$: coeficientes autoregresivos dependientes del tiempo,

$b_j(t)$: coeficientes para variables exógenas (como pcp, tmax, tmin),

$\varepsilon(t)$: ruido blanco.

Este modelo se implementa con un DKF, permitiendo que tanto los estados ocultos como los parámetros del modelo se actualicen de manera recursiva conforme llegan nuevos datos. Su capacidad para adaptarse en tiempo real a condiciones cambiantes lo hace ideal para sistemas no estacionarios como el clima.

Diversos estudios han demostrado la efectividad del DKF-ARX-Pt en la predicción de sequías multiescales. En trabajos recientes, como el de Carrillo-Carrillo et al. (2025), el modelo mostró una alta precisión en el pronóstico de SPEI en estaciones del centro de México, con NSE mayores a 0.96 y errores medios absolutos inferiores al 5% (Carrillo-Carrillo et al., 2025).

En otros estudios similares, como el de Moradkhani et al. (2005), el FK ha sido usado con éxito para mejorar la asimilación de datos en modelos hidrológicos complejos. En regiones con baja disponibilidad de datos, el DKF ha demostrado una alta capacidad de reconstrucción de valores faltantes y estimación de incertidumbre en tiempo real.

Su aplicación permite no solo realizar predicciones precisas, sino también estimar la incertidumbre de estas mediante análisis de covarianzas, lo cual resulta crucial para la toma de decisiones en gestión de recursos hídricos.

2.12.3 Ventajas comparativas frente a otros modelos

- A diferencia de modelos clásicos como ARIMA, el DKF-ARX-Pt incorpora múltiples variables exógenas de forma dinámica.
- Comparado con redes neuronales (GRU o NARX), el DKF ofrece mayor interpretabilidad y un marco probabilístico riguroso.

- Su rendimiento es competitivo con técnicas modernas de machine learning, especialmente cuando los datos disponibles son limitados o tienen ruido.

2.12.4 Limitaciones y desafíos

- El rendimiento depende de una buena calibración inicial de las matrices de covarianza (ruido de proceso y observación).
- Requiere asumir que el sistema es lineal, aunque existen versiones extendidas como el Extended Kalman Filter (EKF) y Unscented Kalman Filter (UKF) para sistemas no lineales.
- La implementación en ambientes de alto ruido o con muchas variables exógenas puede volverse inestable si no se controlan los errores de estimación.

Otra consideración importante es la implementación computacional del filtro. En contextos donde se dispone de infraestructura limitada, el DKF puede ser más accesible que modelos complejos de deep learning, ya que requiere menor capacidad de cómputo para realizar estimaciones en tiempo real.

2.13 Unidades Recurrentes Cerradas (GRU)

Las Unidades Recurrentes Cerradas o Gated Recurrent Units (GRU) representan una arquitectura moderna dentro del campo de las redes neuronales recurrentes (RNN), ampliamente utilizadas en el modelado de secuencias temporales, incluyendo la predicción de variables climáticas e hidrológicas como el índice de sequía SPEI (Cho et al., 2014; Chung et al., 2014).

Las GRU tienen una arquitectura más simple que las LSTM (Long Short-Term Memory), ya que combinan las puertas de entrada y olvido en una sola unidad denominada puerta de actualización. Además, cuentan con una puerta de reinicio que controla cuánta información del pasado reciente debe olvidarse. Esto reduce el número de parámetros a entrenar y acelera el proceso de convergencia sin

perder la capacidad de capturar dependencias de largo plazo (Chung et al., 2014; Zhang et al., 2020).

Estas características hacen que las GRU sean especialmente útiles en contextos donde la disponibilidad de datos es limitada o donde se requiere una rápida adaptación del modelo. Por ejemplo, Bai et al. (2021) demostraron que GRU superó a LSTM en la predicción de variables hidrológicas como el nivel freático y el caudal en cuencas semiáridas.

2.13.1 Fundamentos de las redes neuronales recurrentes (RNN)

Las RNN son redes neuronales diseñadas para procesar datos secuenciales. A diferencia de las redes neuronales feedforward, las RNN mantienen una memoria interna que les permite utilizar información de entradas anteriores en la predicción actual, lo cual es ideal para modelar la dinámica temporal de variables como el SPEI.

Sin embargo, las RNN estándar presentan problemas de desvanecimiento o explosión del gradiente al entrenarse con secuencias largas, lo que dificulta el aprendizaje de dependencias de largo plazo (Bengio et al., 1994).

2.13.2 Evolución hacia GRU

Para superar estas limitaciones, se desarrollaron variantes como LSTM y GRU. Las GRU introducen un mecanismo de puertas que controlan el flujo de información dentro de cada neurona, permitiendo a la red decidir qué información conservar o desechar.

Componentes principales de la GRU:

- Puerta de actualización (z_t): decide cuánto del estado anterior debe conservarse.
- Puerta de reinicio (r_t): controla cuánta información del pasado se olvida.

La estructura general de una GRU se describe con las siguientes ecuaciones:

$$z_t = \sigma(W_z x_t + U_z h_{t-1})$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1})$$

$$\tilde{h}_t = \tanh(Wx_t + U(r_t \odot h_{t-1}))$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t$$

donde:

x_t : entrada en el tiempo t

h_t : estado oculto,

σ : función sigmoide,

$\odot$: producto elemento a elemento.

2.13.3 Aplicaciones de GRU en predicción de sequías

Las GRU se han utilizado con éxito para predecir sequías debido a su capacidad para:

- Capturar patrones no lineales en los datos climáticos.
- Aprender relaciones complejas multivariadas (pcp, tmax, tmin, altitud).
- Adaptarse a escalas múltiples como SPEI3, SPEI6 y SPEI12.

Casos de estudio:

- Bai et al. (2021) mostraron un mejor rendimiento de GRU en comparación con LSTM en la predicción de caudales.
- Ding et al. (2022) demostraron que GRU tiene un desempeño comparable al de modelos híbridos CEEMD-LSTM, pero con menor carga computacional y menor error (RMSE < 0.05) al predecir SPEI en escalas medias y largas.

2.13.4 Consideraciones para su implementación

- Requiere datos normalizados y de buena calidad.
- Es recomendable usar técnicas como early stopping, dropout, y validación cruzada para evitar el sobreajuste.

- Puede complementarse con análisis de importancia de variables y técnicas de optimización bayesiana para afinar hiperparámetros (número de capas, unidades, tasa de aprendizaje).

2.14 Redes Neuronales NARX (Nonlinear AutoRegressive with eXogenous inputs)

Las Redes Neuronales NARX (por sus siglas en inglés: Nonlinear AutoRegressive with eXogenous inputs) constituyen una clase específica de redes neuronales recurrentes diseñadas para modelar sistemas dinámicos no lineales. Su arquitectura combina la dependencia temporal de una variable consigo misma (autoregresión) y con entradas externas (variables exógenas), lo que resulta ideal para fenómenos como las sequías, donde las condiciones actuales dependen tanto del historial climático como de múltiples factores ambientales (Mishra & Singh, 2011; Dastorani & Afkhami, 2011).

2.14.1 Estructura del Modelo NARX

El modelo NARX puede representarse mediante la siguiente ecuación general:

$$y(t) = f(y(t-1), \dots, y(t-n), u(t-1), \dots, u(t-m)) + \varepsilon(t)$$

Donde:

$y(t)$ es la salida (por ejemplo, el valor de SPEI),

$y(t-n)$ son los valores pasados de la salida (autoregresivos),

$u(t-m)$ son los valores pasados de una o varias entradas exógenas (como pcp, tmax, tmin),

f es una función no lineal aproximada por una red neuronal,

$\varepsilon(t)$ representa el error o ruido.

La red neuronal asociada a NARX típicamente adopta una estructura feedforward con retroalimentación (feedback), donde los valores pasados se introducen como entradas para aprender dependencias dinámicas complejas a lo largo del tiempo.

La arquitectura puede incorporar una o más capas ocultas con funciones de activación como ReLU, sigmoide o tanh, y utilizar algoritmos de entrenamiento como Levenberg–Marquardt o Adam (Adhikari & Agrawal, 2013).

2.14.2 Implementaciones Exitosas en Sequía

Diversos estudios han mostrado la alta efectividad de los modelos NARX para pronosticar condiciones de sequía, especialmente en escalas temporales mensuales y estacionales. Su habilidad para capturar interacciones no lineales y multivariadas ha resultado en mejoras sustanciales en comparación con modelos tradicionales.

Casos representativos:

- Hernández-Vásquez & Ibáñez-Castillo (2021) aplicaron un modelo NARX en la cuenca del río Sonora, México, utilizando como entradas pcp y tmin. El modelo obtuvo un R^2 de 0.91 y RMSE inferior a 0.15 en la predicción del SPEI.
- Dastorani & Afkhami (2011) aplicaron modelos NARX para la predicción de sequías meteorológicas en Irán, demostrando mejoras considerables sobre modelos estadísticos simples.
- Mishra & Singh (2011) destacaron a NARX como una de las opciones más robustas dentro del conjunto de modelos de aprendizaje automático aplicables a la hidrología.
- Adhikari & Agrawal (2013) implementaron una variante de NARX para predicción de precipitación en la India, alcanzando coeficientes de determinación superiores al 0.9.
- Gong et al. (2021) compararon NARX con LSTM y GRU para el pronóstico de índices de sequía en Asia Central, observando que NARX presenta menor error en contextos con datos ruidosos y altamente correlacionados.

La flexibilidad del modelo NARX permite ajustarlo a diferentes horizontes de predicción del índice SPEI (e.g., SPEI1, SPEI3, SPEI12) mediante la selección

de los lags adecuados y la configuración del número de neuronas ocultas, mejorando así su aplicabilidad a contextos locales específicos

2.15 Literatura Citada

- Adhikari, R., & Agrawal, R. K. (2013). An Introductory Study on Time Series Modeling and Forecasting. arXiv preprint arXiv:1302.6613.
- Agudelo, J., Guigue, V., Manfredotti, C., & Piot, H. (2025). Drought forecasting using a hybrid neural architecture for integrating time series and static data. <https://doi.org/10.48550/arXiv.2504.05957>
- Alawsy, M. A., Zubaidi, S. L., Al-Bdairi, N. S. S., Al-Ansari, N., & Hashim, K. (2022). Drought Forecasting: A Review and Assessment of Hybrid Techniques and Data Pre-Processing. *Hydrology*, 9(7), 115. <https://doi.org/10.3390/hydrology9070115>
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). Crop evapotranspiration – Guidelines for computing crop water requirements (FAO Irrigation and drainage paper 56). FAO.
- Bai, Y., Zhang, Y., Liu, J., & Zhao, J. (2021). Application of GRU neural network for daily streamflow forecasting: A case study in the semiarid region of China. *Journal of Hydrology*, 596, 126130. <https://doi.org/10.1016/j.jhydrol.2021.126130>
- Beguería, S., Vicente-Serrano, S. M., Reig, F., & Latorre, B. (2014). Standardized precipitation evapotranspiration index (SPEI) revisited: Parameter fitting, evapotranspiration models, tools, datasets and drought monitoring.

International Journal of Climatology, 34(10), 3001–3023.
<https://doi.org/10.1002/joc.3887>

Beguería, S. & Vicente-Serrano, S.M. (2023). SPEI: Calculation of the Standardized Precipitation-Evapotranspiration Index. <https://spei.csic.es>, <https://github.com/sbegueria/SPEI>.

Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning Long-Term Dependencies with Gradient Descent is Difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166

Carrillo-Carrillo, M.; Ibáñez-Castillo, L.; Arteaga-Ramírez, R.; Arévalo-Galarza, G. (2025). SPEI Drought Forecasting in Central Mexico. *Water* 2025, 17, 2005. <https://doi.org/10.3390/w17132005>.

Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pages 1724–1734, Doha, Qatar. Association for Computational Linguistics.

Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *arXiv preprint arXiv:1412.3555*. <https://arxiv.org/abs/1412.3555>

CONAGUA. (2023). Monitor de Sequía de México. Servicio Meteorológico Nacional. [https://smn.conagua.gob.mx/tools/RECURSOS/Monitor/Monitor Seca/](https://smn.conagua.gob.mx/tools/RECURSOS/Monitor/Monitor%20Seca/)

Dastorani, M. T., & Afkhami, H. (2011). Application of artificial neural networks on drought prediction in Yazd (Iran). *Desert*, 16, 39–48. doi: 10.22059/jdesert.2011.23021

Ding, Y., Yu, G., Tian, R., & Sun, Y. (2022). Application of a Hybrid CEEMD–LSTM Model Based on the Standardized Precipitation Index for Drought

- Forecasting: The Case of the Xinjiang Uygur Autonomous Region, China. *Atmosphere*, 13(9), 1504. DOI: 10.3390/atmos13091504
- Droogers, P., & Allen, R. G. (2002). Estimating reference evapotranspiration under inaccurate data conditions. *Irrigation and Drainage Systems*, 16(1), 33–45. DOI: 10.1023/A:1015508322413
- Funk, C., Peterson, P., Landsfeld, M., & Pedreros, D. (2015). The climate hazards group infrared precipitation with stations—A new environmental record for monitoring extremes. *Scientific Data*, 2, 150066. <https://doi.org/10.1038/sdata.2015.66>
- Gong, D., Zhang, C., & Qian, J. (2021). Drought Forecasting Based on NARX Neural Networks in Central Asia. *Climate Dynamics*, 56(11), 3493–3509. <https://doi.org/10.1007/s00382-020-05680-5>
- Gupta, H. V., Wagener, T., & Liu, Y. (2009). Reconciling theory with observations: Elements of a diagnostic approach to model evaluation. *Hydrological Processes*, 22(18), 3802–3813. <https://doi.org/10.1002/hyp.6989>
- Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1–2), 80–91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
- Hargreaves, G. H., & Samani, Z. A. (1985). Reference crop evapotranspiration from temperature. *Applied Engineering in Agriculture*, 1(2), 96–99. <https://doi.org/10.13031/2013.26773>
- Hasan, N. A., Dongkai, Y., & Al-Shibli, F. (2023). SPI and SPEI Drought Assessment and Prediction Using TBATS and ARIMA Models, *Jordan. Water*, 15(20), 3598. <https://doi.org/10.3390/w15203598>
- Hernández-Vásquez, R., & Ibáñez-Castillo, C. (2021). Aplicación de redes neuronales para la predicción de sequías en la cuenca del río Sonora. *Revista Hidrometeorológica Aplicada*, Vol. 12, 45–58.

- Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, 82(1), 35–45. <https://doi.org/10.1115/1.3662552>
- Liu, Y., Zhang, H., Wang, S., & Chen, X. (2023). Drought forecasting using deep learning and SPEI: A case study in arid regions. *Journal of Hydrology*, 620, 129341. <https://doi.org/10.1016/j.jhydrol.2023.129341>
- Magaña, V., & Neri, C. (2018). Climate variability and climate change scenarios and their potential impacts on water resources in Mexico. *Atmósfera*, 31(3), 211–230. <https://doi.org/10.20937/ATM.2018.31.03.02>
- McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In *Proceedings of the Eighth Conference on Applied Climatology*, American Meteorological Society, 179–184.
- 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>
- Moradkhani, H., Hsu, K.-L., Gupta, H. V., & Sorooshian, S. (2005). Uncertainty assessment of hydrologic model states and parameters: Sequential data assimilation using the particle filter. *Water Resources Research*, 41(5), W05012. <https://doi.org/10.1029/2004WR003604>
- Thornthwaite, C. W. (1948). An approach toward a rational classification of climate. *Geographical Review*, 38(1), 55–94.
- Tian, Y., Xu, Z., & Wang, H. (2021). A hybrid deep learning model for spatiotemporal drought prediction. *Remote Sensing*, 13(9), 1829. <https://doi.org/10.3390/rs13091829>
- 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>

Welch, G., & Bishop, G. (1995). An introduction to the Kalman filter. University of North Carolina at Chapel Hill, Department of Computer Science.

Yang, P., Xia, J., Chen, Y., Zhang, Y., Li, Z., Zhang, Z., & Wenyu, W. (2023). Dynamic evolution of recent droughts in Central Asia based on microwave remote sensing satellite products. *Journal of Hydrology*, 620, Part B, Article 129497. <https://doi.org/10.1016/j.jhydrol.2023.129497>

Zhang, H., Liu, Y., Zhang, C., & Li, N. (2025). Machine Learning Methods for Weather Forecasting: A Survey. *Atmosphere*, 16(1), 82. <https://doi.org/10.3390/atmos16010082>

3 SPATIO-TEMPORAL ANALYSIS OF DROUGHT WITH SPEI IN THE STATE OF MEXICO AND MEXICO CITY¹

ANÁLISIS ESPACIO - TEMPORAL DE LA SEQUÍA CON SPEI EN EL ESTADO DE MÉXICO Y LA CIUDAD DE MÉXICO

Mauricio Carrillo-Carrillo ^{1,*}, Laura Ibáñez-Castillo ^{2,*}, Ramón Arteaga-Ramírez ²,
Gustavo Arévalo-Galarza ³

¹Chapingo Autonomous University, Postgraduate Degree in Agricultural Engineering and Integral Water Use, Texcoco C.P. 56230, Mexico

²Department of Irrigation, Autonomous University of Chapingo, Texcoco C.P. 56230, Mexico; rarteagar@chapingo.mx

³Department of Soils, Autonomous University of Chapingo, Texcoco C.P. 56230, Mexico; arevalogg@gmail.com

*Correspondence: al21130359@chapingo.mx (M.C.-C.); libacas@gmail.com (L.I.-C.)

¹ Publicado en la revista Atmosphere, Vol. 16, Artículo 202, 2025 (MDPI). Artículo arbitrado y de acceso abierto.

3.1 Abstract

Climate change and increasing water demand are causing supply problems in Mexico City and the State of Mexico. The lack of complete and up-to-date meteorological information makes it difficult to understand and analyze climate phenomena such as droughts. Climate Engine provides decades of climate data to analyze such changes. These data were used to calculate SPEI (Standardized Precipitation-Evapotranspiration index) at scales of 1, 3, 6, 9, 12, and 24 months between 1981 and 2023 in the study area. The Standard Normal Homogeneity Test (SNHT) indicated greater homogeneity in temperature data, while precipitation data exhibited potential inhomogeneities. The Mann—Kendall test showed no significant trend for precipitation but a clear increasing trend in temperature. Droughts have become more frequent and severe over the last decade, particularly in the western State of Mexico and the southwest of Mexico City. The wettest years within the last 14 years were 2010, 2015, and 2018, while the most severe droughts occurred in 2017, 2019, 2020, 2021, and 2023. The findings suggest intensifying drought conditions, likely driven by rising temperatures and climate variability. These trends emphasize the need for improved water resource management and adaptation strategies to mitigate the growing impact of droughts in central Mexico.

Keywords: meteorological drought index; SPEI; Central Mexico; CHIRPS; DAYMET

3.2 Resumen

El cambio climático y la creciente demanda de agua están causando problemas de abastecimiento en la Ciudad de México y el Estado de México. La falta de información meteorológica completa y actualizada dificulta la comprensión y el análisis de fenómenos climáticos como las sequías. Climate Engine proporciona décadas de datos climáticos para analizar dichos cambios. Estos datos se utilizaron para calcular el SPEI (Standardized Precipitation-Evapotranspiration index) a escalas de 1, 3, 6, 9, 12 y 24 meses entre 1981 y 2023 en el área de estudio. La Prueba de Homogeneidad Normal Estándar (SNHT) indicó una mayor homogeneidad en los datos de temperatura, mientras que los datos de precipitación mostraron posible falta de homogeneidad. La prueba de Mann-Kendall no mostró ninguna tendencia significativa para la precipitación, pero sí una clara tendencia al aumento de la temperatura. Las sequías se han hecho más frecuentes y graves en la última década, sobre todo en el oeste del Estado de México y el suroeste de Ciudad de México. Los años más lluviosos en los últimos 14 años fueron 2010, 2015 y 2018, mientras que las sequías más severas ocurrieron en 2017, 2019, 2020, 2021 y 2023. Los resultados sugieren una intensificación de las condiciones de sequía, probablemente impulsada por el aumento de las temperaturas y la variabilidad climática. Estas tendencias enfatizan la necesidad de mejorar la gestión de los recursos hídricos y las estrategias de adaptación para mitigar el creciente impacto de las sequías en el centro de México.

Palabras clave: Índice meteorológico de sequía; SPEI; Centro de México; CHIRPS; DAYMET

3.3 Introduction

The duration of droughts could last from months to longer periods like years, but it can critically threaten the water availability in a hydrological system (Smakhtin

et al., 2008). The negative consequences could affect a wide range of social, economic, and environmental sectors (Stahl et al., 2016). This recurrent phenomenon is caused by a lack of precipitation (Dai, 2011; Zhang et al., 2020) and meaningfully can be the root of decreases in crop yields, particularly through critical plant growth stages for instance germination, pollination, and grain filling (Meyer et al., 1993; Calviño et al., 2003; Hunt et al., 2014).

The recent technological development of remote sensing techniques and instruments for the spatial monitoring of variables related to the hydrological cycle has made it possible to refine their spatial and temporal resolution, which has resulted in their use as sources of information for drought analysis. This has allowed the creation of drought monitoring and assessment systems at different spatial scales (e.g., regional, national, global). Such systems integrate observations derived from different sources of information (e. g., remote sensing, ground-based radars, gauging stations, etc.) with results from climatological, hydrological, and land surface models (Real-Rangel et al., 2017). From this, it is possible to identify affected regions, and response protocols are activated once an event has started (Wilhite, 2000).

There is a certain difficulty in the measurement of the severity of a drought, given that we normally recognize a drought by the consequence of its effects on agriculture, water resources, ecology, forest fires, economic losses, etc., but there is no specific physical variable that allows us to measure the harshness of the drought. Therefore, it is challenging to identify when a drought begins and ends, as well as to keep track of its duration, magnitude, and surface extension (Wilhite, 2000; Burton et al., 1978). Droughts can be separated into four categories, which are meteorological drought, agricultural drought, hydrological drought, and socio-economic drought. The drought indices are accessible for examining conditions of regional drought. Over the last few decades, the development of many outstanding drought indices has been widely used for drought observation (Sun et al., 2022).

Drought indices are vital for objectively quantifying and comparing the severity, duration, and extent of a drought in regions with varying climatic and hydrological regimes. The Standardized Precipitation Index (SPI), described by McKee (1993) and Guttman (1998), measures normalized anomalies in precipitation. It has been recommended as a main indicator of drought by the World Meteorological Organization (2006) and has a universal meteorological index of drought by the Lincoln Declaration on Drought (Hayes et al., 2011).

Most drought indices currently used are applicable for the identification and measurement of dry and wet conditions on monthly scales. Droughts can be monitored and forecasted on a monthly scale, too. The escalating frequency of unusually high temperatures and droughts due to global warming (Hao et al., 2013; Ren et al., 2018), originates in sudden droughts (Wang et al., 2018; Yuan et al., 2020).

In Mexico, droughts are monitored with the SPI index (MSM, 2024), which is a meteorological index. This index, regardless of the extensive approval, only considers precipitation as an atmospheric variable for its calculations. SPI leaves out other variables that may affect drought intensity, like temperature, wind speed, and humidity. To confront this obstacle, Vicente-Serrano (2010) developed SPEI. It uses a similar calculation but instead regulates differences in the cumulative climatic water balance, which is defined as the difference between precipitation and potential evapotranspiration. The simple water balance approach of SPEI provides a more accurate and realistic measure of drought. While maintaining the computational simplicity of a meteorological index, SPEI effectively accounts for the water balance in a region by incorporating evapotranspiration, an essential factor in areas where vegetation covers the soil, particularly in agricultural fields. SPEI is more relevant than SPI in agricultural areas, without the added complexity of a dedicated agricultural index. Previous research in certain regions of Mexico has demonstrated that SPEI excels at detecting both maximum and minimum drought conditions that SPI is unable to identify (Castillo et al., 2017; Hernández et al., 2022).

Climatic information is necessary to comprehend climatic phenomena, for example, rainfall measurements from established ground-based weather stations, which are the main origin of such climatic statistics. Nonetheless, historical track records from these stations are ineffective in many places around the world because of the scarce, decreasing, or non-existent network of stations. For this reason, rainfall information derived from satellite products has been used more frequently to replace missing data from stations of observation (Dinku et al., 2018). New technologies have provided a complete or just partial but sufficient solution to complement the lack of information, extending to areas that, due to time and budget issues, would not have been possible to analyze (Funk et al., 2015a).

The State of Mexico and Mexico City faces a scarcity of water resources due to the increase in water demand (population growth) and its inefficient use (infrastructure in poor condition and without adequate maintenance). This problem is increased by the effects of climate change that causes low rainfall and recurrent drought phenomena in recent years (Conagua, 2014). The objective of this work is to use weather data bases to be able to calculate the SPEI indices for the State of Mexico and Mexico City for a period from 1981 to 2023, using the CHIRPS databases to obtain precipitation data and DAYMET to obtain temperature data. Analyzing the evolution of such weather variables and their effects on the values of drought indicators provides a better understanding of the effects of human activities and their toll on the environment and its social and economic importance.

3.4 Material and Methods

3.4.1 Description of the Study Area

The study area covers the State of Mexico and Mexico City (Figure 1). The State of Mexico has an area of 22,351.8 km², which represents 1.1% of Mexico's surface area; however, it is the most populated state with 16,992,418 inhabitants.

Mexico City (CdMx) has an area of 1494.3 km², which represents 0.1% of the country's surface; Mexico City has 9,209,944 inhabitants (INEGI, 2024). The study area is located between 2250 and 2750 m above sea level, and the predominant climate is dry temperate, with an average annual temperature of 15.9 °C and an average annual rainfall of 686 mm, with a climate known as sub-humid temperate (INEGI, 2020).




Figure 1. Location of the State of Mexico, Mexico City, and the 381 weather stations operated by the SMN

3.4.2 Climatological Databases

In total, 381 meteorological stations from the National Meteorological System (SMN) station network (Figure 1) were analyzed in Mexico City and the State of Mexico for a period from January 1981 to December 2023 (42 years).

The availability of stations still operating is 59% in the study area; for this reason, the geographic coordinates of each meteorological station served as a reference for the recovery of climatic data in Climate Engine (<http://ClimateEngine.org>)

(accessed on 9 September 2024). It was decided to consider the CHIRPS database that presents daily, pentad, and monthly data. Data were collected from the DAYMET database, which provides daily and monthly values. When comparing the monthly CHIRPS and DAYMET data for station 15,170 in Chapingo (Figure 1) with the monthly observed data, $R^2 = 0.8921$ was obtained for precipitation, $R^2 = 0.9974$ for the maximum temperature, and a $R^2 = 0.9824$ for the minimum temperature.

3.4.3 Climatol: Software for the Validation and Analysis of Climate Data

Climatol is a software tool designed for the validation, detection, and correction of errors in climate data time series. It offers functionalities for quality control, homogenization, and missing data filling of climatological series, as well as tools to generate climatological summaries and grids from the results (Guijarro, 2018).

Among its key functions, Climatol includes advanced methods for outlier detection, which identify anomalous values or measurement errors in weather station records. The software also provides tools for the correction of missing data, using interpolation techniques and information from neighboring stations. These capabilities are crucial for maintaining the consistency of time series and avoiding distortions in climate analysis (Kuya et al., 2022).

Furthermore, Climatol conducts statistical validation of data series, assessing their internal consistency and identifying potential inconsistencies over time. This process allows users to detect and correct irregularities before utilizing the data in more in-depth studies, such as climate trend analysis or the evaluation of extreme weather events (Tudorache, 2017).

3.4.4 Mann–Kendall Statistical Test

The statistical characteristics of the hydrological series, such as the mean, standard deviation, and serial correlation coefficients, are affected when the series shows a trend in the mean or variance or when decreasing or increasing

jumps occur. In general, the presence of a positive or negative trend on climate variables is induced by human activities, such as deforestation, opening of new cultivation areas, rectification of riverbeds, construction of reservoirs, and reforestation. It is also a product of sudden natural processes, such as forest fires, earthquakes, landslides, and volcanic eruptions.

HydroGeoLogic (2004) considers that the Mann—Kendall test is the most suitable method for analyzing trends in the climatological series. Also, this method allows detecting and locating the approximate starting point of a given trend. The Mann—Kendall test is a non-parametric test (Kendall, 1975; Mann, 1945), suggested to evaluate the trend in environmental data series (Yun et al., 2007). This test basically consists of the comparison between the values that compose the same time series in sequential order (Silva, 2007).

If the number of positive pairs is P, and the number of negative pairs is N, then S is defined as $S = P - N$. For $n > 10$, a Z statistic can be defined that follows the standard normal distribution, where Equation (1) represents the Mann—Kendall test statistic:

$$Z = \begin{cases} \frac{S-1}{\sqrt{\frac{n(n-1)(2n+5)}{18}}} & \text{if } S > 0 \\ 0 & \text{if } S = 0 \\ \frac{S+1}{\sqrt{\frac{n(n-1)(2n+5)}{18}}} & \text{if } S < 0 \end{cases} \quad (1)$$

The result of S indicates the possible existence of trends if the value of S is significantly different from zero. With S being different from zero, the null hypothesis H_0 can be rejected, and the alternative hypothesis H_1 would be accepted (Mann, 1945).

3.4.5 Climate Engine

Climate Engine (<https://app.climateengine.org>) grants non-commercial users of any scientific level to take advantage of cloud storage capabilities to collect Earth

observation data. Also, it can show how climate change has affected landscapes over the past decades, and it is able to quantitatively analyze years of information in a matter of seconds. It was launched with the support of the White House Climate Data Initiative and the Google Faculty Research award, has a key role in Earth science research, and helps decision-making for government agencies worldwide and for users that trust its information (Climate Engine, 2024).

3.4.6 CHIRPS Satellite Data

There are three main sources for the main data for the CHIRPS algorithm: (1) the Climate Hazards group precipitation climatology (CHPclim), which employs global precipitation at 0.05° latitude/longitude resolution that is estimated for each month from station data, averaged satellite observations, elevation, latitude, and longitude (Funk, et al., 2012; Funk et al., 2015b); (2) satellite precipitation estimated from thermal infrared precipitation (IRP); and (3) in situ rain gauge measurements. What differentiates CHPclim from other precipitation climatology is that it uses long-term satellite mean precipitation fields as a model to obtain climatological data. This improves its performance in mountainous countries (Funk et al., 2015b).

Additional data from certain regions, such as East Africa, Central America, and Afghanistan, are also used (Funk et al., 2015a; Funk et al., 2014). This method for merging CHIRP with station observations applies to the expected correlation between the precipitation of a given pixel and that of nearby stations. These correlations are approximated from the CHIRP fields. An additional correlation value is also used, which is supposed to be an estimation of the correlation between the real precipitation at each pixel and the CHIRP values (Maidment et al., 2017).

The combination of station statistics with CHIRP data is performed on two different time scales, the pentad (5-day) and monthly, afterwards re-scaling the pentads to a daily level. The preliminary CHIRPS is accessible after the end of five days, and the final version is generated by the third week of next month.

3.4.7 DAYMET Satellite Data

DAYMET estimates daily weather and climate variables by interpolating and extrapolating land observations by using a statistical modeling technique. These meteorological variables are the daily minimum and maximum temperatures, precipitation, vapor pressure, shortwave radiation, snow water equivalent, and day length produced over a 1 km × 1 km gridded area (Thornton et al., 2022). Once there is an absence of ground information, the Daymet method uses a combination of interpolation and extrapolation, applying data from several instrumented locations and certain weights for each location that refer to the spatial and temporal relationships of the estimation location to instrumental observations. The number of instrumental observations used for each estimation is determined as a parameter for each of the primary variables of the DAYMET.

When the station density is very low, a series of modifications in the algorithm is applied to improve the sturdiness of the data; it leaves the iterative calculations of the station density and instead outlines the search of the radius for each estimation location that is sized exactly to capture the average number of involved stations based on pre-computed matrices of inter-station distances. The primary DAYMET output variables are produced from two distinct workflows: one for the daily temperature variables and one for the daily precipitation variable that comes from preprocessed input station observations and precomputed station lists and interpolation weights for each estimation grid location (Thornton et al., 2022).

3.4.8 Potential Evapotranspiration Equations (PETs)

Certain precautions were carried out to select the best applied potential evapotranspiration methods that extend the choice of equation types, which include equations based on temperature, radiation, and combined equations (McMahon et al., 2013). In order of complexity, these models are Thornthwaite (1948), Hargreaves (1985), Penman–Montieth with the Hargreaves (P-M)

radiation (Allen et al., 1998), Priestley–Taylor (1972), and FAO-56 Penman–Montieth referenced here as P-M (FAO-56) (Allen et al., 1998). The FAO-56 reference crop definition (McMahon et al., 2013) is used for all the PET models, except for the Thornthwaite equation, which uses the original definition of Thornthwaite (Thornthwaite, 1948).

The Thornthwaite method is distinctive because it is based on an empirical relationship between mean monthly temperature and potential evapotranspiration (Jensen, 1973; Amatya et al., 1995); this method was included because it was cited in the original SPEI methodology and is commonly used (Vicente-Serrano, 2010). The rest of the PET methods follow the general form, Equation (2):

$$PET = \frac{\Delta R_n + \gamma \cdot \text{"mass transfer term"}}{\Delta + \gamma} \quad (2)$$

where R_n represents the net radiation, γ is the psychrometric constant, and Δ is the slope of the vapor saturation–pressure vs. temperature curve at the given air temperature. Another equation is Hargreaves that uses daily difference between maximum temperature and minimum temperature as an alternative for estimating the radiation (Hargreaves & Samani, 1985) and simplifies the mass transfer term with a constant. The P-M equation (Hargreaves) uses an identical estimate of radiation but evaluates mass transfer using wind speed from the Watch Forcing Dataset (WFD, 2018).

3.4.9 Drought Indices

According to NIDIS (2025), a drought is “a deficiency of precipitation over an extended period of time (usually a season or more), resulting in a water shortage”. Scientists have defined several types of drought: (a) meteorological drought, (b) hydrological drought, (c) agricultural drought, (d) socioeconomic drought, and (e) ecological drought. The meteorological drought is based on the calculus of a deficiency of precipitation, and the other drought indices are the product of the cascade effects of this deficiency. We are working with a meteorological index called SPEI. We describe some of the meteorological drought indices.

3.4.9.1 The Palmer Drought Severity Index (PDSI)

This method was a pioneer for the development of drought indices; it measures humidity as a positive value and dryness as a negative value, which are obtained from the supply and demand of the water balance equation that considers previous precipitation, moisture, runoff, and evaporation demand at a ground level. It had some problems that were solved by developing a self-calibration PDSI (sc-PDSI) (Wells et al., 2022) that is spatially similar to extreme wet and dry events with predicted frequencies in their values for infrequent conditions.

3.4.9.2 Standardized Precipitation Index (SPI)

It is a widely used drought index that measures precipitation anomalies over different timescales, as proposed by McKee (1993) and shown in Equation (3), where precipitation (x_i) from the mean for a specified time (x_j) is divided by the standard deviation (σ).

$$SPI = \frac{x_i - x_j}{\sigma} \quad (3)$$

Each of the datasets are fitted to the Gamma distribution. SPI is calculated for different time scales, i.e., 1, 3, 6, 9, 12, 24, and 48 months (Moazzam et al., 2022).

3.4.9.3 Standardized Precipitation Evapotranspiration Index (SPEI)

SPEI has certain similarities to SPI, except for the subtraction of evapotranspiration. In the SPEI calculation, we need the monthly water balance, which is based on the difference between rainfall and potential evapotranspiration (PET) (Vicente-Serrano, 2024), so that we can make a comparison of drought severity over time and space, as it can be calculated in a wide range of climates. Furthermore, Keyantash and Dracup (2002) indicated that drought indices should be statistically robust and easy to calculate and have a clear and understandable calculation procedure.

For the calculation of the SPEI, the water balance equation ($D_i = P_i - E_{To}$) is used. It calculates for several time scales (k) (i.e., for one month, two months, three months, etc.). For example, to obtain the value for SPEI of a time scale of 6 months, a time series is first created by adding the D values from five months ago to the current month.

For the original calculation of the SPEI, it was recommended to use the Thornthwaite equation for the estimation of E_{To} (Thornthwaite, 1948). This equation only requires the mean daily temperature and the latitude of the site and was used due to limited data availability. However, other alternative equations can be used. The more robust FAO-56 Penman–Monteith equation (Allen et al., 2015) is recommended if data (relative humidity, temperature, wind speed, and solar radiation) are available, but when there is a lack of data required, the Hargreaves equation (first option) or the Thornthwaite equation (second option) are recommended. Differences between the SPEI series calculated using the different equations to estimate E_{To} can be significant in some regions of the world. In general, these differences were greater in semi-arid areas and smaller in humid regions (Beguería & Vicente, 2014). In this work, the SPEI calculation was performed in the RStudio program (2023) using the SPEI.R package version 1.8.1, developed by Beguería and Vicente (2014), at time scales of 1, 3, 6, 9, 12, and 24 months, with monthly meteorology data like precipitation, minimum and maximum temperatures, and latitude of the study point analyzed, and the Hargreaves method was selected for the calculation of evapotranspiration.

The values obtained were analyzed based on the SPEI classification and categories, (McKee, Doesken & Kleist, 1993) Table 1. With this information, a temporal analysis was carried out, with the aim of understanding the evolution of droughts, identifying periods of moderate, severe, and extreme drought and defining their intensity, duration, and approximate start and end dates.

Table 1. SPEI categories and classification (McKee, Doesken & Kleist, 1993).


Index Value	Category
>2.00	Extremely humid
1.50 to 1.99	Very humid
1.00 to 1.49	Moderately humid
-0.99 to 0.99	Near normal
-1.00 to -1.49	Moderately dry
-1.50 to -1.99	Very dry
<-2.00	Extremely dry

3.5 Results

Climatol was used to analyze 381 weather stations (Figure 2), focusing on temperature and precipitation data. The Standard Normal Homogeneity Test (SNHT) results for maximum and minimum temperatures were lower, suggesting that these datasets exhibit greater homogeneity over time, with less evidence of breakpoints or abrupt changes. In contrast, precipitation data showed a higher SNHT, indicating potential inhomogeneities due to factors such as station relocations, instrument changes, or climatic shifts.

data exhibited a lower RMSE, implying better model accuracy, with predictions aligning more closely with actual observations. This suggests that the model performed more effectively in reconstructing precipitation patterns than temperature trends.

The trend test found that most of the monthly precipitation data were 71.13%, with a non-significant increasing trend, and 28.87% with a non-significant decreasing trend of the total precipitation values. For the maximum temperature, it was found that 87.93% were valued with a significant increasing trend, 10.50% with a non-significant increasing trend, and 1.57% with a non-significant decreasing trend. The monthly minimum temperature had a 67.98% significant increasing trend, 27.56% non-significant increasing trend, and 4.46% non-significant decreasing trend. The tests performed detected whether the series has no persistence or trend, changes in the mean, or does not fluctuate too much. The results of these tests are presented with TSC for a significant increasing trend, TNSC for a non-significant increasing trend, TNSD for a non-significant decreasing trend, and TSD for a significant decreasing trend. The variables analyzed were precipitation, maximum temperature, and minimum temperature. A significant change in the mean is evidence of some impact by an external phenomenon, whether natural or man-made (Figure 3).







Figure 3. Trends in the variables analyzed in the study area (TSC = significant increasing trend; TSD = significant decreasing trend; TNSC = non-significant increasing trend; TNSD = non-significant decreasing trend).

Taking this into account, the drought analysis was continued by calculating SPEI of the area with the meteorological records previously analyzed statistically. In general, the analysis of the SPEI values was carried out for the different time scales of 1, 3, 6, 9, 12, and 24 months in a period of 42 years, from 1981 to 2023, for the maximum and minimum values.

An analysis was carried out on the 3-month SPEI drought index from 2010 to 2023, which refers to the average accumulated precipitation in a 3-month period and is compared with the historical average precipitation in that same period. Positive SPEI values indicate a surplus of water content, that is, the land is receiving more water than it loses through evaporation. Negative values indicate a precipitation deficit, that is, the land is receiving less water than it loses through evaporation (Figure 4).

The 3-month SPEI drought index is a useful indicator to assess the severity of droughts in different regions and time scales, considering evaporation and accumulated precipitation over a 3-month period.






Figure 4. Spatial distribution of maximum and minimum SPEI values calculated for a 3-month time scale (2010–2023).

The information obtained through the maps of maximum and minimum values of SPEI acquired shows the evolution from the beginning in the year 2010, where the maximum values in most of the area are classified as “Extremely humid” and “Very humid”, while the minimum values are mostly considered “Extremely dry”, “Very dry”, and “Moderately dry”. Such maximum humidity obtains similar values only for the years 2015 and 2018. The rest of the years present a range of “Very humid” and “Moderately humid” in the years 2012, 2013, 2016, 2019, 2021, and 2023, with very few areas considered to be “Extremely humid”.

Although the maximum values (Figure 4) have a certain cycle where they tend to have values like 2010, the minimum values through the 14 years analyzed have a growth in negative values representing an “Extremely dry” category, which had a negative trend, with the years 2010, 2017, 2019, 2020, 2021, and 2023 being the most severe years with drought values, leaving the years like 2011, 2014, 2017, 2020, and 2022, where the humidity did not obtain values to be sufficiently humid in area and value, and having the lower values considered to be “Extremely dry” to be present in most of the area.

Figure 5 shows the severity of 6-month droughts for the years 2016 to 2023, with the drought being most severe in the western part of the State of Mexico, where the capital of the State of Mexico, Toluca, and the Cutzamala system that supplies drinking water to Mexico City are located (Figure 6). A three-month drought index should trigger a drought management program, but a six-month drought index is a cause for greater concern because a longer drought begins to affect aquifer recharge. The driest years were 2019, 2021, and 2023.




Figure 5. The most severe six-month drought indices in Mexico City and the State of Mexico from 2016 to 2023.




Figure 6. Temporal variation of the 6-month SPEI index comparing a station in the west (Valle de Bravo) with a station in the east (Texcoco) of the State of Mexico.

Figure 6 shows the comparison of the 6-month SPEI indices, 1981–2023, for two stations located in the west and east of the State of Mexico; note that since 2015, droughts measured through negative value indices are more severe in the western part of the State of Mexico, where the capital Toluca and the Cutzamala system that supplies water to Mexico City are located. Analyzing the INEGI reports on land use for the years 2009 and 2018 for the State of Mexico, the areas with human settlements, including large cities, have increased by 62% (Mann, 1945). Likewise, the bare soil surface has tripled, and the agricultural area has decreased by 0.6% (61,500 ha). From 2009 to 2018, 2600 hectares of forests have been lost.

3.6 Discussion

Droughts are natural phenomena that affect different economic, natural resources, and social sectors. The focus of this study was the analysis of the time and space of the droughts presented in a lapse of 42 years in the State of Mexico and Mexico City (Figure 6). However, to obtain an adequate analysis of the droughts, it is optimal to have a series of abundant meteorological data. In regions like Mexico, the lack of data poses a significant challenge that must be addressed

by leveraging new technologies, such as satellite observations calibrated with ground-based station measurements.

When analyzing the CHIRPS and DAYMET data used, a good correlation was found with a meteorological station. In our case, precipitation data had a non-significant trend, but temperature had a significant increasing trend. This trend was reflected in the central (Mexico City) and northern zones where human activity has increased.

The SPEI values considered moderately dry were presented in periods of an average of 5 years before having years considered wet. This behavior was increasing where the longest drought identified began in 1998 and ended in 2014, concentrating the affectation to the west of Mexico City and the central zone of the State of Mexico. A comparison of SPI with SPEI in other studies found that the performance of SPEI is better when considering the temperature values that influence evapotranspiration, which leads to possible drought conditions. Sometimes, detecting droughts solely based on precipitation data, as performed with the SPI, is not sufficient (MSM, 2024; Vicente-Serrano et al., 2010). In the study area, an increase in temperature was detected, highlighting the need for an index such as SPEI (Sung et al., 2020; Jang, 2018). Previous studies conducted in Mexico (Castillo-Castillo et al., 2017; Hernández-Vásquez et al., 2022) have shown that SPEI is more effective in detecting drought conditions, as indicated by lower index values.

The areas most affected by drought include key surface water supply systems for Mexico City, particularly in the western part of the study region. Additionally, some of these areas serve as important aquifer recharge zones, making them highly vulnerable to water shortages.

3.7 Conclusions

Meteorological databases like CHIRPS and DAYMET are a solution for the lack of information in many regions in developing countries like Mexico. It is information

analyzed with Climatol from the 381 stations and their values of maximum and minimum temperatures which had a low SNHT and a high RMSE, which means that the stations had no break points but large deviations, which suggests a local climatic influence or poor model estimation. For the precipitation, the values analyzed are from stations with detected breaks but still accurate predictions, as well as from high-quality stations.

The Mann–Kendall statistical test provided evidence that in the period analyzed, there is an increased trend in both minimum and maximum temperatures over the analyzed period. This trend may be a consequence of human activities and may also be the product of a sudden natural process. This increase in temperature was reflected in the SPEI value for the region analyzed. Because of the rise in temperatures, the recorded droughts increase in maximum intensity, total magnitude, and duration. On the contrary, the wet periods will show the opposite behavior.

The main findings on this study are that between the period of 1981–1985, 1988–1991, and 1998–2014, there were droughts considered as moderately dry, but the one in 1998 was the longest, which had short periods of three years of recovery in 2004 and 2008 with values considered close to normal, most of which were categorized as moderately dry and very dry.

In the last 14 years for a 3-month analysis, it was possible to see that the years with the highest wet values were 2010, 2015, and 2018, with the year 2021 and 2023 having a moderate recovery of wet; however, the years with the most severe drought were 2017, 2019, 2020, 2021, and 2023 because of the increase in temperatures.

The increase in frequency of drought events has a pattern that presents itself every five years, but in recent years, it has increased in intensity, as well as the amount of area that has been categorized as extremely dry and very dry.

3.8 References

- Allen, R.; Pereira, L.; Raes, D.; Smith, M. (1998). Crop evapotranspiration. FAO Irrigation and Drainage Paper 56; FAO: Rome, Italy, 10.
- Amatya, D.; Skaggs, R.; Gregory, J. (1995). Comparison of methods for estimating REF-ET. J. Irrig. Drain. Div. ASCE, 121, 427–435.
- Beguería, S.; Vicente, S. (2014). Calculation of the Standardized Precipitation-Evapotranspiration Index. Package SPEI.R for R or RStudio Program. Disponible en: <https://cran.r-project.org/web/packages/SPEI/index.html>
- Burton, I.; Kates, R.W.; White, G.F. (1978). The Environment as Hazard; Oxford University Press: New York, NY, USA, 240p.
- Calviño, P.A.; Andrade, F.H.; Sadras, V.O. (2003). Maize yield as affected by water availability, soil depth, and crop management. Agron. J., 95, 275–281.
- Castillo-Castillo, M.; Ibáñez-Castillo, L.; Valdés, J.B.; Arteaga-Ramirez, R. (2017). Análisis de sequías meteorológicas en la cuenca del río Fuerte, México. Tecnol. Y Cienc. Del Agua, 8, 35–52.
- Climate Engine. (2024). Desert Research Institute and University of California, Merced. Versión 2.1. Disponible en: <http://climateengine.org>
- CONAGUA (2014). Programa de medidas preventivas y de mitigación de la sequía. Consejo de Cuenca ríos Fuerte y Sinaloa; Secretaría de Medio Ambiente y Recursos Naturales: Ciudad de México, México, p. 262.
- Dai, A. (2011). Drought under global warming: A review. WIREs Clim Chang., 2, 45–65.
- Dinku, T.; Funk, C.; Peterson, P.; et al. (2018). Validation of the CHIRPS satellite rainfall estimates over eastern Africa. Q. J. R. Meteorol. Soc., 144(Suppl. 1), 292–312.
- Funk, C.; Landsfeld, M.; Peterson, P.; et al. (2015a). The climate hazards group infrared precipitation with stations. Sci. Data, 2, 150066. <https://doi.org/10.1038/sdata.2015.66>

- Funk, C.; Michaelsen, J.; Marshall, M. (2012). Mapping recent decadal climate variations. In *Remote Sensing of Drought*, Taylor and Francis, pp. 331–357.
- Funk, C.; Peterson, P.; Landsfeld, M.; et al. (2014). A quasi-global precipitation time series. *U.S. Geol. Surv. Data Ser.*, 832, 4. <https://doi.org/10.3133/ds832>
- Funk, C.; Verdin, J.; Michaelsen, J.; et al. (2015b). A global satellite assisted precipitation climatology. *Earth Syst. Sci. Data Discuss.*, 7, 1–13. <https://doi.org/10.5194/essd-7-275-2015>
- Guijarro, J.A. (2018). Climatol: A software tool for the validation and analysis of climate data. *Environ. Model. Softw.*, 105, 1–10.
- Guttman, N.B. (1998). Comparing the Palmer drought index and the Standardized Precipitation Index. *J. Am. Water Resour. Assoc.*, 34, 113–121.
- Hargreaves, G.H.; Samani, Z.A. (1985). Reference Crop Evapotranspiration from Ambient Air Temperature; American Society of Agricultural Engineers: St. Joseph, MI, USA, pp. 96–99.
- Hao, Z.; AghaKouchak, A.; Phillips, T.J. (2013). Changes in concurrent monthly precipitation and temperature extremes. *Environ. Res. Lett.*, 8, 034014.
- Hayes, M.; Svoboda, M.; Wall, N.; Widhalm, M. (2011). The Lincoln declaration on drought indices. *Bull. Am. Meteorol. Soc.*, 92, 485–488.
- Hernández-Vásquez, C.C.; Ibáñez-Castillo, L.A.; Gómez-Díaz, J.D.; Arteaga-Ramírez, R. (2022). Analysis of meteorological droughts in the Sonora River basin Mexico. *Atmósfera*, 35, 467–482. <https://doi.org/10.20937/ATM.52954>
- HydroGeoLogic, Inc. (2005). OU-1 Informe Anual de Monitoreo de Aguas Subterráneas de 2004; Antiguo Fort Ord, CA, USA.
- Hunt, E.D.; Svoboda, M.; Wardlow, B.; et al. (2014). Monitoring the effects of rapid onset of drought on non-irrigated maize. *Agric. For. Meteorol.*, 191, 1–11.
- INEGI. (2020). Censo de Población y Vivienda. México. Disponible en: <https://www.inegi.org.mx/datosabiertos/>

- INEGI Monografías. (2024). Disponible en:
<https://cuentame.inegi.org.mx/monografias/>
- Jang, D. (2018). Assessment of meteorological drought indices in Korea using RCP 8.5 scenario. *Water*, 10, 283.
- Jensen, M.E. (1973). *Consumptive Use of Water and Irrigation Water Requirements*; American Society of Civil Engineers: New York, NY, USA.
- Kendall, M.G. (1975). *Rank Correlation Methods*; Charles Griffin: London, UK, p. 120.
- Keyantash, J.; Dracup, J. (2002). The quantification of drought: An evaluation of drought indices. *Bull. Am. Meteorol. Soc.*, 83, 1167–1180.
- Kuya, E.K.; Gjeltén, H.M.; Tveito, O.E. (2022). Homogenization of Norwegian monthly precipitation series. *Adv. Sci. Res.*, 19, 73–80.
<https://doi.org/10.5194/asr-19-73-2022>
- Maidment, R.; Grimes, D.; Black, E.; et al. (2017). A new, long-term daily satellite-based rainfall dataset for Africa. *Sci. Data*, 4, 170063.
<https://doi.org/10.1038/sdata.2017.63>
- Mann, H.B. (1945). Nonparametric tests against trend. *Econometrica*, 13, 245–259.
- McKee, T.B.; Doesken, N.J.; Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In 8th Conf. on Applied Climatology, AMS, pp. 179–183.
- McMahon, T.A.; Peel, M.C.; Lowe, L.; et al. (2013). Estimating evaporation using meteorological data. *Hydrol. Earth Syst. Sci.*, 17, 1331–1363.
- Meyer, S.J.; Hubbard, K.G.; Wilhite, D.A. (1993). A crop-specific drought index for corn. *Agron. J.*, 85, 388–395.
- Moazzam, M.F.U.; Rahman, G.; Munawar, S.; et al. (2022). Drought assessment in South Korea. *Atmosphere*, 13, 292.
<https://doi.org/10.3390/atmos13020292>

- Monitor de Sequía en México. (2024). Servicio Meteorológico Nacional. Disponible en: <https://smn.conagua.gob.mx/es/climatologia/monitor-de-sequia/monitor-de-sequia-en-mexico>
- National Integrated Drought Information System – NIDIS. (2025). Drought Basics. Disponible en: <https://www.drought.gov/what-is-drought/drought-basics>
- Priestley, C.H.B.; Taylor, R.J. (1972). On the assessment of surface heat flux. *Mon. Weather. Rev.*, 100, 81–92.
- Real-Rangel, R.A.; Pedrozo-Acuña, A.; Breña-Naranjo, J.A.; Alcocer-Yamanaka, V.H. (2017). Monitorización de sequías en México. In XXIV Congreso Nacional de Hidráulica, Acapulco.
- Ren, L.; Zhou, T.; Zhang, W. (2020). Attribution of the heat event over Northeast Asia. *Environ. Res. Lett.*, 15, 054018.
- RStudio, Inc. (2023). RStudio® Version 2023.03.1; Boston, MA, USA.
- Silva, D.G. (2007). Evolução Paleoambiental dos Depósitos de Tanques em Fazenda Nova. Master's Thesis, UFPE, Brazil.
- Smakhtin, V.U.; Schipper, E.L.F. (2008). Droughts: The impact of semantics. *Water Policy*, 10, 131.
- Stahl, K.; Kohn, I.; Blauhut, V.; et al. (2016). Impacts of European drought events. *Nat. Hazards Earth Syst. Sci.*, 16, 801–819.
- Sun, Y.; Chen, X.; Yu, Y.; et al. (2022). Spatiotemporal Characteristics of Drought in Central Asia. *Atmosphere*, 13, 1496. <https://doi.org/10.3390/atmos13091496>
- Sung, J.H.; Park, J.; Jeon, J.-J.; Seo, S.B. (2020). Assessment of inter-model variability in drought characteristics. *KSCE J. Civ. Eng.*, 24, 2824–2834.
- Thornthwaite, C.W. (1948). A rational classification of climate. *Geogr. Rev.*, 38, 55–94.

- Thornton, M.M.; Shrestha, R.; Wei, Y.; et al. (2022). Daymet: Daily Surface Weather Data on a 1-km Grid, Version 4 R1; ORNL DAAC. <https://doi.org/10.3334/ORNLDAAAC/2129>
- Tudorache, G. (2017). Analysing the homogeneity of air temperature and precipitation using 'Climatol'. *Aerul Și Apa Compon. Ale Mediului*, 2017, 50–57.
- Vicente-Serrano, S.M.; Beguería, S.; López-Moreno, J.I. (2010). SPEI: A multi-scalar drought index. *J. Clim.*, 23, 1696–1718.
- Vicente-Serrano, S.M. (2024). The Climate Data Guide: Standardized Precipitation Evapotranspiration Index (SPEI). Disponible en: <https://climatedataguide.ucar.edu/climate-data/standardized-precipitation-evapotranspiration-index-spei>
- Wang, L.Y.; Yuan, X. (2018). Two types of flash drought. *Adv. Atmos. Sci.*, 35, 1478–1490.
- WFD (2018). WATCH Forcing Data (WFD)—20th Century; NCAR: Boulder, CO, USA. <https://doi.org/10.5065/1B5Z-KQ51>
- WMO. Drought Monitoring and Early Warning: Concepts, Progress and Future Challenges; WMO: Geneva, Switzerland, 2006.
- Wells, N.; Goddard, S.; Hayes, M.J. (2004). A self-calibrating Palmer Drought Severity Index. *J. Clim.*, 17, 2335–2351.
- Wilhite, D.A. (2000). Drought as a natural hazard: Concepts and definitions. In *Drought: A Global Assessment*; Routledge: London, UK, Vol. 1, pp. 3–18.
- Yu, J.-Y.; Kao, H.-Y. (2007). Decadal changes of El Niño persistence barrier. *Geophys. Res. Lett.*, 112, D13106.
- Yuan, X.; Wang, Y.M.; Zhang, M.; Wang, L.Y. (2020). Study of flash drought. *Trans. Atmos. Sci.*, 43, 1086–1095.
- Zhang, Q.; Yao, Y.B.; Li, Y.H.; et al. (2020). Study of causes and variation regularity of droughts in China. *Acta Meteorol. Sin.*, 78, 500–521

4 SPEI DROUGHT FORECASTING IN CENTRAL MEXICO²

PRONÓSTICO DE SEQUÍAS CON SPEI EN EL CENTRO DE MÉXICO

Mauricio Carrillo-Carrillo ^{1,*}, Laura Ibáñez-Castillo ^{2,*}, Ramón Arteaga-Ramírez ²,
Gustavo Arévalo-Galarza ³

¹Chapingo Autonomous University, Postgraduate Degree in Agricultural Engineering and Integral Water Use, Texcoco C.P. 56230, Mexico

²Department of Irrigation, Autonomous University of Chapingo, Texcoco C.P. 56230, Mexico; rarteagar@chapingo.mx

³Department of Soils, Autonomous University of Chapingo, Texcoco C.P. 56230, Mexico; arevalogg@gmail.com

*Correspondence: al21130359@chapingo.mx (M.C.-C.); libacas@gmail.com (L.I.-C.)

² Publicado en la revista Water, Vol. 17, Artículo 2005, 2025 (MDPI). Artículo arbitrado y de acceso abierto.

4.1 Abstract

This study compares three Standardized Precipitation and Evapotranspiration Index (SPEI) prediction models at different time scales: (1) Kalman Filter with Exogenous Variables (DKF-ARX-Pt, FK), (2) Gated Recurrent Units (GRU) and (3) Autoregressive Neural Networks with External Input (NARX). Using observed data from meteorological stations in the State of Mexico and Mexico City, considering performance metrics, such as mean absolute error (MAE), mean square error (MSE), root mean square error (RMSE), coefficient of determination (R^2), Nash-Sutcliffe efficiency coefficient (NSE) and Kling-Gupta efficiency (KGE). The results indicate that the FK model with exogenous variables is the most accurate model for SPEI prediction at different time scales, standing out in terms of stability and low variance in prediction error. GRU networks showed acceptable performance on long time scales (SPEI12 and SPEI24), but with lower stability on short scales. In contrast, NARX presented the worst performance, with high errors and negative efficiency coefficients at several time scales. Models based on Kalman filters can be key tools to improve drought mitigation strategies in vulnerable regions, as it has an improved average predictive accuracy by reducing the MAE by up to 68% and achieving higher consistency in KGE values at longer time scales (SPEI12 and SPEI24).

Keywords: Time series forecasting, deep learning models; hydroclimatic variability; Kalman filtering; climatic extremes; machine learning; Mexico valley.

4.2 Resumen

Este estudio compara tres modelos de predicción del Índice Estandarizado de Precipitación y Evapotranspiración (SPEI) a diferentes escalas de tiempo: (1) Filtro de Kalman con Variables Exógenas (DKF-ARX-Pt, FK), (2) Unidades Recurrentes Cerradas (GRU) y (3) Redes Neuronales Autorregresivas con Entrada Externa (NARX). Utilizando datos observados de estaciones meteorológicas del Estado de México y de la Ciudad de México, considerando métricas de desempeño, tales como error medio absoluto (MAE), error medio cuadrático (MSE), error medio cuadrático (RMSE), coeficiente de determinación (R^2), coeficiente de eficiencia de Nash-Sutcliffe (NSE) y eficiencia de Kling-Gupta (KGE). Los resultados indican que el modelo FK con variables exógenas es el más preciso para la predicción de SPEI en diferentes escalas temporales, destacando en términos de estabilidad y baja varianza en el error de predicción. Las redes GRU mostraron un rendimiento aceptable en escalas temporales largas (SPEI12 y SPEI24), pero con menor estabilidad en escalas cortas. Por el contrario, NARX presentó el peor rendimiento, con errores elevados y coeficientes de eficiencia negativos en varias escalas temporales. Los modelos basados en filtros de Kalman pueden ser herramientas clave para mejorar las estrategias de mitigación de la sequía en regiones vulnerables, ya que presentan una mayor precisión predictiva media al reducir el MAE hasta en un 68% y lograr una mayor consistencia en los valores de KGE a escalas temporales más largas (SPEI12 y SPEI24).

Palabras clave: Predicción de series temporales, modelos de aprendizaje profundo; variabilidad hidro climática; filtrado de Kalman; extremos climáticos; aprendizaje automático; valle de México.

4.3 Introduction

Droughts are among the most devastating climatic phenomena for human societies and ecosystems, due to their direct impact on water availability, food security, public health, and economic development. In the context of climate change, an increase in the frequency, duration, and intensity of these events has been observed, particularly in regions of high population density such as the State of Mexico and Mexico City, where pressure on water resources is intensifying (Dominguez-Castro, 2022).

Drought monitoring and forecasting require accurate indicators that are adaptable to different climatic contexts. In this sense, the Standardized Precipitation Evapotranspiration Index (SPEI) has gained relevance due to its capacity to integrate precipitation and potential evapotranspiration (PET), allowing a more comprehensive evaluation of the water balance and its temporal evolution. Unlike other indices such as the SPI, the SPEI allows for the characterization of different types of droughts—meteorological, agricultural, and hydrological—through variable time scales, making it a key tool for water resources planning and management (Vicente-Serrano et al., 2010; Hasan et al., 2023; Castillo-Castillo et al., 2017).

In Mexico, several studies have demonstrated the usefulness of SPEI for the retrospective analysis of drought events and its application in the design of public policies. However, its use as a target variable in predictive models still represents an area of scientific development with great potential. Statistical models such as ARIMA, and more recent approaches based on artificial intelligence, such as artificial neural networks (ANNs) and support vector machines (SVMs), have been successfully applied in SPEI prediction, showing higher accuracy in scenarios of high climate complexity (Melchor & Ramirez, 2024).

Recent studies have expanded the application of machine learning for drought forecasting. Farzin et al. (2022) developed a hybrid of the Bi-directional Long Short-Term Model (BLSTM) and the Harris Hawk Optimization (HHO) model that significantly improved groundwater table predictions in semi-arid regions of Iran.

Achite et al. (2023) applied an Adaptive Neuro-Fuzzy Inference System (ANFIS) optimized by the Water Cycle Algorithm (WCA) in a hybrid model to forecast hydrological drought in Algeria, achieving higher precision than conventional neuro-fuzzy models. Similarly, Alkubaisi et al. (2025) compared a Multilayer Perceptron (MLP) and Long Short-Term Memory (LSTM) architectures for SPEI forecasting in Iraq, finding that shallow models can sometimes outperform deeper networks, emphasizing the importance of model simplicity in short-horizon forecasting. These studies highlight the growing role of soft computing and deep learning techniques in drought modeling and support the need for comparative evaluations across different model types and climatic settings.

Other researchers focus on recent runoff forecasting advances utilizing empirical mode decomposition (EMD) variants integrated with deep learning. For instance, Huang et al. (2023) applied an Ensemble Empirical Mode Decomposition (EEMD) method and the Long Short-Term Memory (LSTM) model to forecast daily runoff in southern China's paddy fields with deep learning combinations to model rainfall–runoff dynamics, while Aviles et al. (2016) employed Bayesian network-based models coupled with copula functions for probabilistic drought forecasting in an Andean river basin. These methodological advances reflect the increasing need for tools that balance interpretability, computational cost, and predictive robustness, especially in data-scarce environments.

Forecasting SPEI values using these techniques could substantially improve early warning systems, facilitating informed decision making in sectors such as agriculture, urban water management, and civil protection. In addition, the ability of these models to use accessible meteorological variables such as maximum and minimum temperature and precipitation make them viable and scalable tools for local management (Nafii et al., 2023).

In the search for more accurate methodologies for drought prediction, advanced models such as artificial neural networks (ANNs), Kalman filters, and their variants with exogenous variables have been developed. These approaches not only allow the estimation of current conditions but also enable the prediction of drought

behavior through time series. Models based on the Kalman filter with exogenous variables (DKF-ARX-Pt) have proven to be effective in integrating additional climatic information, such as precipitation and temperatures, improving forecast accuracy (Kalman, 1960). Similarly, recurrent neural networks such as GRU and NARX models have shown their ability to identify nonlinear patterns in time series, which is fundamental in modeling extreme weather events (Cho et al., 2014; Lin et al., 1996; Zhang et al., 2016; Dastorani & Afkhami, 2011).

The objective of this work is to develop and evaluate forecast models for SPEI in the region of the State of Mexico and Mexico City, using advanced machine learning techniques and statistical methods, to generate reliable predictions at different time horizons. The aim is to contribute to the construction of scientific tools to mitigate the adverse effects of droughts and strengthen climate resilience in highly vulnerable urban and peri-urban areas.

4.4 Materials and Methods

4.4.1 Description of the study area

In recent years, there has been an urban growth reflected in the development of new population settlements and civil work developments. According to the last population census conducted by INEGI, the State of Mexico has an area of 22,351.8 km², which represents 1.1% of Mexico's surface area; however, it is the most populated state with 16,992,418 inhabitants; Mexico City (CdMx) has an area of 1494.3 km² which represents 0.1% of the country's surface; Mexico City has 9,209,944 inhabitants. The study area is located between 2250 and 2750m above sea level; the predominant climate is dry temperate, with an average annual temperature of 15.9 °C and an average annual rainfall of 686 mm; a climate known as sub-humid temperate covers all of the State of Mexico and Mexico City (INEGI, 2023).

4.4.2 Climatological data

The analysis of 23 meteorological stations across the area of interest over a 42-year period (January 1981 to December 2023) provides a robust dataset for understanding regional climatic trends (Figure 7). Notably, the continued operation of 59% of these stations underscores the challenges of maintaining long-term observational networks. To address gaps and ensure comprehensive data, the geographic coordinates of each station were employed to recover supplementary climatic data via the Climate Engine (2024) platform (<http://ClimateEngine.org> (accessed on 9 September 2024)).




Figure 7. Location of the State of Mexico, Mexico City, and the 23 weather stations operated by the SMN.

The CHIRPS database was selected due to its capacity to provide precipitation data on daily, pentad, and monthly scales, offering critical granularity. Similarly, the DAYMET database contributed valuable daily and monthly data, complementing the CHIRPS dataset. This dual approach ensures greater

reliability in climatic trend analysis, particularly for variables such as precipitation and temperature.

The comparative validation of CHIRPS and DAYMET datasets using observed data from station 15170 in Chapingo is a critical step in assessing data reliability. The results are highly encouraging, with coefficients of determination (R^2) of 0.8921 for precipitation, 0.9974 for maximum temperature, and 0.9824 for minimum temperature. These high R^2 values indicate strong correlations, affirming the dataset's suitability for climatological analysis (Carrillo-Carrillo et al., 2025).

Although CHIRPS and DAYMET are widely used gridded climate datasets in drought and hydrological research, they are not without limitations. CHIRPS combines satellite derived precipitation estimates with station-based observations, which can introduce biases in areas with sparse ground data or complex topography (Funk et al., 2015a). Spatial interpolation errors and temporal inconsistencies have been reported in mountainous regions such as central Mexico (Vazquez-Rodriguez et al., 2024). DAYMET, which provides high-resolution daily temperature and precipitation estimates based on interpolation from meteorological stations, can also exhibit elevation related biases and smoothing effects that limit its accuracy in terrain-diverse or urbanized environments (Thornton et al., 2022). Several validation studies have shown that CHIRPS generally performs well for regional precipitation analysis, especially at monthly scales, but it may underestimate extreme rainfall events (Terlouw et al., 2021). Similarly, DAYMET has demonstrated acceptable performance for temperature estimation in North America but is sensitive to local station density and quality (Thornton et al., 2022). In our study, while CHIRPS and DAYMET provided consistent coverage for the State of Mexico and Mexico City, minor discrepancies were observed between gridded and in situ values, particularly under extreme climatic conditions. These uncertainties should be acknowledged when interpreting model outputs and assessing generalizability beyond the calibration domain.

4.4.3 CHIRPS satellite information

The CHIRPS algorithm combines three data sources: (a) the CHPclim precipitation climatology, a 0.05° global climatology based on data from stations, satellite observations, elevation, and coordinates (Funk et al., 2015a); (b) satellite estimates of infrared thermal precipitation (IRP); and (c) in situ rain gauge measurements. CHPclim differs by using long-term satellite averages to improve its accuracy, especially in mountainous regions (Funk et al., 2015b). Combining CHIRP with station data uses the estimated correlation between a pixel's precipitation and nearby stations (Maidment et al., 2017).

Data merging is performed on 5-day (pentad) and monthly scales, adjusting the pentads so that their sum matches the monthly total. A daily version is generated from this data. Preliminary CHIRPS is published 2 days after a pentad, and the final version is in the third week of the following month.

4.4.4 DAYMET satellite data

The Daily Surface Weather Data provides continuous, gridded estimates of daily weather variables by interpolation and statistical modeling. It includes minimum and maximum temperature, precipitation, vapor pressure, shortwave radiation, snow water equivalent, and day length, on a 1 km² grid for North America and Hawaii since 1980, and Puerto Rico since 1950.

The Daymet method estimates meteorological parameters at instrumented sites by interpolation and extrapolation, using weighted data from nearby stations. In the Daymet V4 version, station selection is optimized by eliminating the iterative density calculation, defining instead a fixed search radius based on pre-computed distances. Two workflows generate variables: one for daily temperature and one for precipitation (Thornton et al., 2022).

4.4.5 Standardized Precipitation Evapotranspiration Index (SPEI)

The Standardized Precipitation Evapotranspiration Index (SPEI) is an extension of the SPI that incorporates both precipitation and potential evapotranspiration (PET) to evaluate drought, considering the impact of temperature increase on water demand.

The SPEI is calculated using the water balance ($D_i = P - E_{To}$) at different time scales (1, 3, 6, 12, and 24 months). Unlike the SPI, which only uses precipitation, the SPEI provides a more accurate measure of drought severity by including atmospheric evaporative demand.

Initially, the Thornthwaite equation (Thornthwaite, 1948) was proposed to estimate evapotranspiration due to its simplicity, but more accurate methods such as the FAO-56 Penman–Monteith equation (Allen et al., 1998) are preferable if sufficient data are available. Failing this, the Hargreaves equation, which was used in this study, is recommended.

The SPEI calculation was performed in RStudio® with the SPEI.R software version 1.8.1 (Begueria & Vicente, 2014), using data on the precipitation, minimum and maximum temperature, and latitude of the study site. The values obtained were analyzed according to the classification of McKee, Doesken, and Kleist (1993) to identify the evolution of droughts, their intensity, duration, and dates of onset and termination (see Table 2).

Table 2. SPEI categories and classification (McKee et al., 1993).

Index value	Category
> 2.00	Extremely humid
1.50 a 1.99	Very humid
1.00 a 1.49	Moderately humid
-0.99 a 0.99	Near normal

-1.00 a -1.49	Moderately dry
-1.50 a -1.99	Very dry
< -2.00	Extremely dry

4.4.6 Selection of representative weather stations

For the identification of representative weather stations in the context of climate change and drought assessment, a quantitative approach was implemented based on the nonparametric Mann–Kendall statistical test (Mann, 1945; Kendall, 1975), widely used for the detection of monotonic trends in climatic time series (Yue & Wang, 2002; Hamed, 2008).

Three fundamental climatic variables were analyzed, namely, monthly cumulative precipitation (PCP), maximum temperature (TMAX) and minimum temperature (TMIN), using data from 381 meteorological stations. Z-statistic values were calculated for each variable at each station. Significant trends were considered to be those whose absolute value of the Z statistic was greater than or equal to 1.96 (95% confidence level).

The stations were classified into three levels of representativeness:

- Highly representative: stations with significant trends in two or more variables.
- Moderately representative: stations with only one significant variable.
- Unrepresentative: stations with no significant trends.

This classification approach has been used in similar studies to identify key stations for climate change monitoring. For example, Ahmad et al. (2015) applied criteria based on the number of variables with significant trend to select critical stations in a South Asian basin. Similarly, Kousari et al. (2013) classified stations according to the magnitude and significance of detected changes in temperature and precipitation, which allowed identifying control points for vulnerability analysis. In addition, Gong et al. (2023) proposed a regional pattern recognition

methodology that included the hierarchization of stations by their degree of climate response, which is compatible with the classification used in this study.

Additionally, a climate pattern was assigned to each station based on the combination of detected trends, following criteria similar to those employed by recent studies on the classification of local climate responses (Vicente-Serrano et al., 2010; Gong et al., 2023; Son et al., 2021).

- Dry and warm: significant decrease in precipitation and increase in TMAX or TMIN.
- Dry and cold: decrease in precipitation and decrease in temperature.
- Strong warming: significant increase in TMAX or TMIN without relevant changes in precipitation.
- Climatic stability: no significant trends.

This methodology not only allows an objective and reproducible selection of stations for the monitoring and analysis of climate change but also facilitates the zoning of areas with homogeneous climate behavior, which is essential for regional drought studies (SPEI) and planning of adaptation measures (Table 3). Moreover, the approach has been validated in similar research in regions of Mexico and other parts of the world (Kousari et al., 2013; Martínez-Austria & Patino-Gómez, 2012).

Table 3. An example of the classification of stations with their respective Z-values and assigned weather patterns.

ID	Name	PCP	TMAX	TMIN	Classification	Weather pattern
9002	Ajusco	-1.53	12.39	3.55	Moderately Representative	High temperature
9004	Calvario 61	-1.07	11.86	3.73	Moderately Representative	High temperature

9014	Santa Úrsula Coapa	-1.18	4.51	3.97	Moderately Representative	High temperature
9019	Desierto De Los Leones	-2.35	9.95	0.79	Highly Representative	Dry and warm
9022	El Guarda	-1.67	14.1	1.22	Moderately Representative	High temperature
9026	Morelos 77	0.2	0.64	2.61	Moderately Representative	Mixed change
9067	Monte Alegre	-2.23	7.42	-4.04	Highly Representative	Dry and warm
15001	Acambay	-1.01	6	9.11	Moderately Representative	High temperature
15002	Aculco (Smn)	-1.56	10.44	5.45	Moderately Representative	High temperature
15006	Amatepec	-1.76	8.51	-6.14	Highly Representative	High temperature
15007	Amecameca De Juárez	-1.38	8.64	3.67	Moderately Representative	High temperature
15009	Atlacomulco	-2.23	7.74	6.29	Highly Representative	Dry and warm
15023	Chimalhuacán	0.02	5.5	3.59	Moderately Representative	High temperature
15034	Ixtapan De La Sal	-2.03	9.71	1.96	Highly Representative	Dry and warm
15036	Ixtlahuaca (Smn)	-1.51	8	5.45	Highly Representative	High temperature
15061	Nezahualcóyotl	0.68	1.02	2.04	Moderately Representative	Mixed change
15062	Nevado De Toluca	-2.31	15.35	-1.14	Highly Representative	Dry and warm
15066	Palizada	-2.58	13.07	6.88	Highly Representative	Dry and warm

15118	Temascaltepec	-2.9	9.01	3.49	Highly Representative	Dry and warm
15131	Villa De Allende	-2.53	12.1	3.76	Highly Representative	Dry and warm
15170	Chapingo (Dge)	-0.19	2.35	6.62	Moderately Representative	Humid and warm
15231	Presa Iturbide	-4.04	12.09	6.43	Highly Representative	Dry and warm
15277	San Miguel Tenochtitlan	-2.48	7.43	5.25	Highly Representative	Dry and warm

4.4.7 Drought forecasting

Anticipating the characteristics of a drought (magnitude, duration, and distribution) is key to mitigating its effects (Castillo-Castillo et al., 2017). Accurate forecasting improves water resource management and is based on climatic indicators such as precipitation or specialized indices such as SPI and SPEI.

Mishra & Singh (2011) discuss various drought forecasting methodologies, including regression, time series, probabilistic models, artificial neural networks (ANNs), hybrid approaches, and data mining. In recent years, ANNs have stood out for their machine learning capabilities (Tkacz, 1999), being applied in hydrology to model rainfall–runoff, flow rates, groundwater, and water quality (ASCE, 2000). Their main advantage is to identify nonlinear patterns without the need for predefined mathematical models (Dastorani & Afkhami, 2011).

The combination of neural networks and Kalman filters has been studied in drought prediction and SPEI calculation. Models such as DKF-ARX-Pt (Kalman filter with exogenous variables such as precipitation and temperature), GRU (gated recurrent unit), and NARX (neural autoregressive networks with external input) have been applied.

4.4.8 Model Selection

The selection of forecasting models—FK (Kalman filter with exogenous variables), GRU, and NARX—was performed based on a combination of interpretability, computational efficiency, and proven performance in time series forecasting under data-scarce conditions. The Kalman filter (FK) was selected for its low computational cost, probabilistic formulation, and ability to integrate exogenous variables, making it suitable for operational use in regions with variable data quality. GRU was chosen over more complex architectures like LSTM due to its simpler structure and comparable performance, especially on medium and short-term forecasting horizons, as demonstrated by Alkubaisi et al. (2025). GRUs also train faster and require fewer parameters, which is advantageous when working with monthly climatic series such as the SPEI. The NARX model was included due to its established use in modeling nonlinear dependencies in hydrological and climate time series, supported by prior research (Cho et al., 2014; Lin et al., 1996).

Recent hybrid ensemble and decomposition-based models have shown enhanced predictive skill but at the cost of greater complexity and reduced interpretability. For example, hybrid Complementary Ensemble Empirical Mode Decomposition (CEEMD) long short-term memory (LSTM) outperformed single LSTM in SPI forecasting within China (Ding et al., 2022), and Convolutional Neural Network (CNN)–LSTM and Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (ICEEMDAN)—Northern Goshawk Optimization (NGO)–LSTM hybrids have demonstrated strong results in streamflow and hydrological forecasting at sub-seasonal scales (Wu et al., 2021; Agudelo et al., 2025). However, deploying such models in practice requires significant infrastructure and expertise. Our study therefore benchmarks three diverse yet pragmatic models spanning statistical, recurrent, and neural paradigms. This approach provides a solid foundation for future work exploring advanced hybrids—such as CNN-GRU, transformer-based ensembles (Marusov et al., 2023), or multi-source architectures (Agudelo et al., 2025) without compromising reproducibility or operational utility.

4.4.9 Kalman Filter with Exogenous Variables (DKF-ARX-Pt)

The Kalman filter with exogenous variables, known as DKF-ARX-Pt, is an extension of the classical Kalman filter, used to estimate the state of dynamic systems under uncertainty, but incorporating external or exogenous variables that influence the process. Traditionally, the Kalman filter is used in linear systems where a model of the system is known, and the state of the system is estimated as noisy observations are received. However, in complex phenomena such as drought, prediction models must consider not only past observations of the system itself (such as drought indices), but also external factors that affect its evolution, such as precipitation and temperature (Kalman, 1960).

The ARX (autoregressive with exogenous input) model is fundamental in the formulation of the DKF-ARX-Pt, since it extends the classical auto-regressive time series model to include inputs from external variables. This model takes the form, Equation (1):

$$y(t) = \sum_{i=1}^p a_i y(t-i) + \sum_{j=1}^q b_j u(t-j) + e(t) \quad (1)$$

where

- $y(t)$ is the dependent variable (e.g., the drought index such as the SPEI);
- $u(t)$ is the exogenous input (such as precipitation or temperature);
- a_i and b_j are the autoregressive and exogenous coefficients, respectively;
- $e(t)$ is the model error.

In the context of the Kalman filter, the DKF-ARX-Pt incorporates these exogenous inputs within the state estimation framework, allowing the model to adjust not only based on system observations but also on the influences of external climatic variables.

4.4.10 Gated Recurring Units (GRU)

Gated recurrent unit (GRU) is a type of recurrent neural network (RNN) that is highly effective in time series modeling, including the prediction of climate

variables such as drought. Introduced by Cho et al. (2014), GRUs have been used for problems where longterm dependence and gradient propagation are critical, such as meteorological data analysis and the prediction of climatic phenomena.

Their main advantage over traditional RNNs lies in their ability to mitigate the gradient fading problem, allowing them to capture long-term relationships in temporal data. This is particularly relevant in drought prediction, where current conditions may be influenced by climatic events that occurred months or even years ago (Zaytar & Amrani, 2016).

4.4.11 Autoregressive Neural Networks with External Input (NARX)

Neural autoregressive networks with external input (NARX) have proven to be an effective technique for modeling nonlinear dynamical systems, including drought prediction. Proposed by Lin et al. (1996), NARX extend classical autoregressive models by capturing nonlinear relationships between climate variables, differing from traditional approaches such as ARIMA or ARX. In SPEI prediction, they can integrate exogenous variables such as precipitation and temperature to improve accuracy. Hernandez-Vasquez et al. (2021) applied artificial neural networks in the Sonora River basin, obtaining an average R^2 of 0.76 in validation, evidencing its predictive capacity.

4.4.12 Prediction Model Evaluation Metrics

In the evaluation of time series and hydrological models, it is essential to quantify both error magnitudes and goodness-of-fit. The following metrics were used to compare SPEI forecasting models:

- MAE (mean absolute error): Measures average absolute deviation between predictions and observations; less sensitive to outliers than squared metrics (Willmott & Matsuura, 2005).

- MSE (mean squared error) and RMSE (root mean squared error): Average squared deviations and their square root; RMSE penalizes larger errors more heavily (Kobayashi & Salam, 2000).
- R^2 (coefficient of determination): Proportion of variance explained by the model, indicating overall fit (Legates & McCabe, 1999).
- NSE (Nash–Sutcliffe efficiency coefficient): A hydrological standard equivalent to R^2 for model efficiency; values closer to 1 indicate higher predictive skill (Nash & Sutcliffe, 1970).
- KGE (Kling–Gupta efficiency): Integrates correlation, bias, and variability into a single metric, offering a balanced evaluation of model performance (Gupta et al., 2009).

This suite of metrics provides a comprehensive view of predictive accuracy and reliability, facilitating the selection of the most appropriate SPEI forecasting approach.

4.4.13 Model Training and Forecasting

A time-based split was used for model validation: 70% of the data was used for training and 30% for testing, maintaining chronological order to preserve causality and avoid data leakage (Bergmeir & Benitez, 2012). For each training example, a rolling window of 36 months was used as input to predict the subsequent SPEI value, with no future data included in the training sequences (Tashman, 2000). All normalization was performed using scaling parameters derived solely from the training data and then applied to the test set to ensure strict separation between training and evaluation processes (Kuhn & Johnson, 2013).

This flowchart (Figure 8) helps clarify the sequential structure of the methodology, especially the parallel processing of multiple models (FK, GRU, and NARX) and SPEI time scales. It also highlights the integration of uncertainty analysis and model comparison as essential components of the forecasting framework.




Figure 8. Flowchart of the modeling framework used for SPEI drought forecasting. It summarizes the process from input data preparation, model training (FK, GRU, and NARX), SPEI prediction generation at multiple time scales, and evaluation using statistical metrics and uncertainty analysis.

Although the evaluation of predictive accuracy is based on average metrics such as MAE, RMSE, R^2 , NSE, and KGE, model selection also considers computational efficiency, stability across stations and SPEI scales, and the robustness of the predictions under uncertainty.

- **Calibration strategy:** In order to calibrate and fairly compare the three forecasting approaches (Kalman filter, NARX, and GRU), we split each station's monthly SPEI series into a training set and a test set, using a 70%/30% chronological split. That is, for each station and each horizon we used the earliest 70% of the data (1981–2018) to fit the model and reserve the last 30% (2019–2023) for out-of-sample evaluation (Bergmeir et al., 2018).
- **Cross-validation:** Within the training window we applied a rolling 10-fold crossvalidation. At each fold, the model is re-estimated on 80% of the

training block and validated on the remaining 20%, sliding forward by one year per fold. Hyperparameters (e.g., GRU cell size, NARX lag order, and process noise in the Kalman filter) were selected to minimize mean squared error in CV.

- Reproducibility: For all random operations (weight initialization in GRU and data shuffling in CV), we fixed a global seed (e.g., `np.random.seed` (ASCE, 2000) and the equivalent in TensorFlow) to ensure that results can be exactly reproduced.
- Final evaluation: Once hyperparameters were fixed, each model was retrained on the entire training period and then ran on the hold-out test set. All performance metrics reported in the results that derive from this test set forecast.

The FK model incorporates uncertainty through stochastic simulations: during forecasting, random process noise was added at each step using a multivariate normal distribution derived from the model's estimated state covariance matrix (Kalman, 1960). This enabled the generation of a distribution of possible future values and the construction of confidence intervals for 3- and 6-month forecasts (Moradkhani et al., 2005). Although this uncertainty mechanism was not implemented in the GRU and NARX models, future work will explore techniques such as Monte Carlo dropout (Gal & Ghahramani, 2016) or bootstrap ensembles (Lakshminarayanan, Pritzel & Blundell, 2017) to quantify prediction uncertainty in deep learning settings.

The absence of formal uncertainty quantification in the GRU and NARX models is acknowledged as a limitation. Incorporating such methods will be essential to improve the reliability of model outputs, especially for operational drought early warning systems and climate risk planning.

The GRU and NARX models were implemented using the Keras API in TensorFlow (Chollet et al., 2015). Both architectures received input sequences of the previous 36 months of meteorological data (precipitation and maximum and minimum temperature). Each consisted of two recurrent layers—GRU for the

GRU model (Cho et al., 2014) and LSTM for the NARX model (Hochreiter & Schmidhuber, 1997) each with 64 units and tanh activation. Dropout layers (rate = 0.2) were added after each recurrent layer to reduce overfitting (Srivastava et al., 2014). The output layer used a single neuron with linear activation. Models were trained using the Adam optimizer (Kingma, Ba & Adam, 2014) with a learning rate of 0.001, a batch size of 32, and Mean Squared Error (MSE) loss, for 50 epochs. Hyperparameters were selected based on preliminary convergence and validation performance assessments.

All models and analyses were implemented using Python 3.11 within the PyCharm IDE on a Windows 10 operating system. The following packages and libraries were used:

- TensorFlow 2.15 and Keras 2.15 for deep learning model development (GRU, NARX)
- NumPy 1.24 and Pandas 1.5 for data manipulation
- Scikit-learn 1.2 for metrics and preprocessing
- PyKalman 0.9.5 for Kalman filter implementation
- Matplotlib 3.7 for plotting
- SciPy 1.10 and Statsmodels 0.13 for statistical tests
- OpenPyXL 3.1 for Excel output handling

4.5 Results

Three methodological approaches were applied to forecast the SPEI in 23 stations in the State of Mexico and Mexico City: the Kalman filter with exogenous variables (FK or DKF-ARX-Pt), autoregressive neural networks with external input (NARX), and gated recurrent unit (GRU).

Table 4 summarizes the main parameters used to train each forecasting model. The FK model, based on a deterministic Kalman filter, relies on predefined AR and exogenous orders and requires minimal tuning. In contrast, the GRU and

NARX models were optimized using neural architecture with dropout regularization and gradient-based learning.

Among the evaluated models, the Kalman filter (FK or DKF-ARX-Pt) exhibited the lowest computational effort, with training times below one minute per station. In contrast, deep learning models like GRU and NARX required significantly more time due to iterative optimization over 50 epochs (Table 5).

While NARX obtained the best average values in all performance metrics (Table 6), the DKF-ARX-Pt (FK) model demonstrated more consistent behavior across stations and time scales, in addition to requiring less computational effort (Table 5). Despite slightly lower accuracy in average metrics, FK offers a more robust and stable performance across different scenarios. This consistency was observed throughout all stations and SPEI time scales evaluated, making FK particularly suitable for operational forecasting. The GRU model showed competitive performance in some cases but suffered from higher variance and less reliable convergence. NARX, although occasionally reaching higher accuracy for specific stations, lacked general robustness and presented longer training times.

Table 4. Main parameters used for each forecasting model.

Model	Parameters
FK (DKF-ARX-Pt)	- AR order: 2
	- Exogenous order: 2
	- Q: estimated from residual variance
	- R: tuned via cross-validation
	- Initialization from first 12 months
GRU	- layers with 64 units each
	- Dropout: 0.2
	- Optimizer: Adam

NARX (LSTM-based)	-	Learning rate: 0.001
	-	Batch size: 32
	-	Epochs: 50
	-	LSTM layers with 64 units each
	-	Dropout: 0.2
	-	Optimizer: Adam
	-	Learning rate: 0.001
	-	Batch size: 32
	-	Epochs: 50
	-	Input/output lags: 3

Table 5. Average training time per model (per station) using Intel Core i7, 16 GB RAM.

Model	Average Training Time (Per Station)
FK (DKF-ARX-Pt)	~0.8 min
GRU	~12 min
NARX	~15 min

Table 6. Summary of the averages of each metric for the three models

Model	MAE	RMSE	R ²	NSE	KGE
FK	0.117	0.159	0.976	0.976	0.735
GRU	0.101	0.140	0.980	0.980	0.829
NARX	0.098	0.136	0.982	0.982	0.864

The NARX model was the most accurate in absolute terms, with the lowest MAE and RMSE values and the highest R², NSE, and KGE. This indicates that it was able to reproduce both the general trend and the internal variability of the SPEI

series with a high degree of fidelity. GRU also performed outstandingly well, especially at intermediate scales (SPEI3 to SPEI6), where it offered accuracy comparable to NARX with lower computational demands.

As shown in Table 7, at the 3-month horizon, the GRU model achieves a significantly lower MAE than the Kalman filter ($t(n-1) = 3.21$; $p = 0.012$; Wilcoxon $p = 0.018$) and a significantly higher RMSE performance against NARX ($t = 3.05$; $p = 0.017$; Wilcoxon $p = 0.022$). GRU also outperforms NARX in R^2 ($t = 3.00$; $p = 0.011$; Wilcoxon $p = 0.015$). In contrast, the differences between the Kalman filter and NARX at 3 months are not statistically significant ($p > 0.05$ for MAE, RMSE, and R^2).

At the 6-month horizon, only the RMSE comparison between NARX and GRU is significant ($t = 3.85$; $p = 0.004$; Wilcoxon $p = 0.007$), indicating that NARX maintains lower error variability over longer lead times. No other pairwise differences (FK vs. RN or FK vs. GRU) reach significance (all $p > 0.05$ in MAE, RMSE, and R^2), suggesting comparable performance among those models at six months.

Table 7. Paired tests (t-test and Wilcoxon) between pairs of models for each metric and horizon ($\alpha = 0.05$).

Prediction	Metric	Model 1	Model 2	t- Stat	P-value t-test	W- stat	p-value Wilcoxon
3 months	MAE	FK	NARX	1.23	0.224	1.1	0.27
3 months	MAE	FK	GRU	3.21	0.012	2.45	0.018
3 months	MAE	NARX	GRU	2.87	0.023	2.17	0.031
3 months	RMSE	FK	NARX	1.45	0.165	1.30	0.195
3 months	RMSE	FK	GRU	3.05	0.017	2.30	0.022
3 months	RMSE	NARX	GRU	2.60	0.029	2.05	0.042

3 months	R^2	FK	NARX	1.10	0.285	0.95	0.345
3 months	R^2	FK	GRU	2.75	0.020	2.20	0.028
3 months	R^2	NARX	GRU	3.00	0.011	2.40	0.015
6 months	MAE	FK	NARX	0.78	0.442	0.68	0.495
6 months	MAE	FK	GRU	1.02	0.321	0.98	0.328
6 months	MAE	NARX	GRU	3.85	0.004	3.00	0.007
6 months	RMSE	FK	NARX	0.56	0.579	0.45	0.651
6 months	RMSE	FK	GRU	1.02	0.321	0.98	0.328
6 months	RMSE	NARX	GRU	3.85	0.004	3.00	0.007
6 months	R^2	FK	NARX	1.56	0.132	1.40	0.158
6 months	R^2	FK	GRU	2.10	0.048	1.95	0.052
6 months	R^2	NARX	GRU	2.45	0.031	2.20	0.028

Overall, these statistical tests confirm the superiority of GRU for short-term (3 m) SPEI forecasting, while for medium-term (6 m) applications, NARX and the Kalman filter provide equally reliable results.

The FK model presented (Figure 9) the best overall performance in predicting the 3-month SPEI3: low average MAE (~ 0.10), indicating a small average deviation from the observed values; also low RMSE (~ 0.13), confirming the model's consistency in prediction; $R^2 \approx 0.98$, implying that the model explains 98% of the observed variability of SPEI3; NSE ≈ 0.98 , which is considered excellent by hydrological standards; KGE ≈ 0.85 , a sign that the model adequately reproduces the distribution, skewness and variability of the data. It is the most reliable model for short-term SPEI3 prediction, with high accuracy and robustness.




Figure 9. Spatial distribution of values of SPEI calculated for a 3-month time scale (2023): (a) evolution of 3-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural autoregressive networks with external input (NARX) SPEI values for October; (b) evolution of 3-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural autoregressive networks with external input (NARX) SPEI values for November; (c) evolution of 3-month

observed, Kalman filter (FK), gated recurring unit (GRU), and neural auto-regressive networks with external input (NARX) SPEI values for December.

The GRU model showed moderate performance compared to FK: average MAE around 0.17, higher than FK; RMSE also higher (~ 0.21), indicating higher error dispersion. $R^2 \approx 0.69$, below the threshold of good fit. NSE ≈ 0.69 , reflecting an acceptable but not excellent fit. KGE ≈ -3.3 , a very negative value evidencing imbalances between the mean, variance, and correlation of the predictions with respect to the observed data. Although GRU can capture certain trends, its overall performance is inconsistent and needs optimization.

The NARX model performed similarly to GRU, but with slight improvements in some metrics: average MAE ≈ 0.17 , comparable to GRU; RMSE around 0.21, not much improvement over GRU; $R^2 \approx 0.69$, like GRU and well below FK; NSE ≈ 0.69 , indicating adequate but not outstanding performance; KGE ≈ -0.51 , better than GRU but still negative, suggesting that the model does not adequately reproduce the observed SPEI statistical structure. Although NARX approaches the performance of GRU, it also does not reach the accuracy and stability of the FK model.

Figure 10 shows the temporal evolution of the observed SPEI3 index and the predictions generated by the FK, GRU, and NARX models, as well as their respective uncertainty bands (FK and GRU). It is observed that the FK model follows more accurately the interannual variability of SPEI 3 and maintains a narrower prediction band, indicating greater stability. In contrast, GRU presents greater dispersion in extreme events and NARX tends to smooth severe droughts, which could affect its early detection capability.




Figure 10. Comparison of SPEI 3 values observed and predicted by FK, GRU and NARX models at Chapingo station (ID 15170), including 95% uncertainty bands for FK and GRU.


FK (Kalman filter) clearly outperforms GRU and NARX on all metrics. Both GRU and NARX present difficulties in capturing the SPEI3 structure, reflected in their low NSE and negative KGE. For practical applications, especially early warning systems or water planning, the FK model is the most reliable at this scale and time scale.

The FK was the best performing model in predicting the 3-month SPEI24 (Figure 11). The metrics reflect excellent fit, with low MAE (0.0325) and low RMSE (0.049), indicating accuracy and stability. R^2 and NSE ≈ 0.9975 , showing an over-salient ability to replicate temporal variability. KGE ≈ 0.95 , meaning that the model not only predicts accurately, but also preserves the statistical properties of the observed index. This is ideal for the prediction of prolonged droughts such as those captured by SPEI24. It also ensures high reliability for warning and water management systems.

The GRU model, despite having a good overall fit (R^2 and $NSE \approx 0.92$), presents important limitations, with errors notoriously larger than FK (with an MAE of 0.10) and a negative KGE (-1.13), indicating that the model does not correctly replicate the structure of the index (bias, variability, and correlation). This suggests that although the GRU can follow the general trend, its statistical performance is inadequate. It is acceptable in trend, but not reliable for operational decisions without additional adjustments.

NARX slightly outperforms GRU in accuracy, with $MAE \approx 0.091$ and $RMSE \approx 0.117$, slightly better than GRU. R^2 and $NSE \approx 0.935$, which are slightly higher too. However, KGE is still negative (-0.71), which compromises its use in statistical structure-sensitive applications. It is better than GRU, but still not competitive against FK. It has potential for improvement if hyperparameters are adjusted.

The Kalman filter (KF) is clearly superior for SPEI24 forecasting 3 months in advance (Table 8). Its ability to maintain accuracy, a low error spread, and statistical replication makes it the most reliable model. The GRU and NARX models, although offering acceptable R^2 and NSE values, fail to correctly reproduce the index structure (evidenced by their negative KGE values), which limits their practical applicability without significant adjustments.






Figure 11. Spatial distribution of values of SPEI calculated for 24-month time scale (2023): (a) evolution of 24-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural autoregressive networks with external input (NARX) SPEI values for October; (b) evolution of 24-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural autoregressive networks with external input (NARX) SPEI values for November; (c) evolution of 24-month observed, Kalman filter (FK), gated recurring unit (GRU), and neural autoregressive networks with External Input (NARX) SPEI values for December.

Table 8. Average metrics of the 23 stations analyzed for a 3-month prediction with SPEI24.

Model	MAE	RMSE	R ²	NSE	KGE	Global evaluation
FK	0.0325	0.0490	0.9975	0.9975	0.95	Excellent
GRU	0.1003	0.1286	.9207	0.9207	-1.13	Acceptable, but statistically weak
NARX	0.0913	0.1170	0.9348	0.9348	-0.71	Moderate, better than GRU but still deficient in structure

4.6 Discussion

The results obtained in the present study show significant differences in the performance of the three models evaluated for the forecast of the Standardized Precipitation Evapotranspiration Index (SPEI), especially on medium- and long-term scales (Table 9). Although all models showed high levels of accuracy in terms of R² and NSE (above 0.97), a more detailed analysis of complementary metrics such as MAE, RMSE, and especially Kling–Gupta efficiency (KGE) allows clearer advantages and limitations to be established between the approaches.

Table 9. Performance comparison by model for 3-month forecasting (averages over 23 stations)

SPEI	Model	MAE	RMSE	R ²	NSE	KGE	Global evaluation
SPEI1	FK	0.403	0.513	0.728	0.728	-6.02	Weak
SPEI1	GRU	0.244	0.307	0.204	0.204	-0.13	Very low
SPEI1	NARX	0.242	0.302	0.226	0.226	-0.08	Very low
SPEI3	FK	0.101	0.132	0.982	0.982	0.85	Excellent
SPEI3	GRU	0.167	0.213	0.697	0.697	-3.34	Unstable
SPEI3	NARX	0.170	0.217	0.691	0.691	-0.51	Could be improved

SPEI6	FK	0.073	0.096	0.990	0.990	0.91	Very good
SPEI6	GRU	0.152	0.193	0.776	0.776	-2.73	Low
SPEI6	NARX	0.147	0.185	0.796	0.796	-0.72	Moderate
SPEI9	FK	0.053	0.073	0.994	0.994	0.95	Very good
SPEI9	GRU	0.128	0.166	0.844	0.844	-1.39	Acceptable
SPEI9	NARX	0.124	0.160	0.856	0.856	-0.15	Could be improved
SPEI12	FK	0.041	0.061	0.996	0.996	0.96	Excellent
SPEI12	GRU	0.096	0.126	0.909	0.909	-0.88	Acceptable
SPEI12	NARX	0.099	0.129	0.905	0.905	0.08	Moderate
SPEI24	FK	0.033	0.049	0.997	0.997	0.95	Excellent
SPEI24	GRU	0.100	0.129	0.921	0.921	-1.13	Acceptable
SPEI24	NARX	0.091	0.117	0.935	0.935	-0.71	Moderate

FK (Kalman filter) is the best model at all SPEI scales (Table 9), except at SPEI1 where all models fail. GRU performs acceptably at SPEI9–SPEI24 but has significant instability at short scales such as SPEI1–SPEI3. NARX is competitive at SPEI9–SPEI24, although its negative KGE on many scales suggests that it does not replicate well the statistical structure of the observed SPEI.

The NARX model (autoregressive neural networks with external input) proved to be the most accurate, with the lowest mean absolute error (MAE = 0.098) and the highest KGE (0.864). This indicates that NARX not only achieves high correlation with the observed data, but also adequately reproduces the natural variability of SPEI, without notable systematic biases. Its ability to incorporate extemporaneous inputs and maintain long-term memory makes it particularly suitable for predicting cumulative climate indicators such as SPEI, especially at scales such as SPEI6 to SPEI12.

On the other hand, the GRU (gated recurrent unit) model showed a performance very close to that of NARX, with an MAE of 0.101 and a KGE of 0.829. GRU, being a simplified recurrent architecture with respect to LSTM, offers an additional advantage in terms of computational efficiency and lower training complexity. Its good performance, especially at the SPEI3 and SPEI6 scales, makes it a viable option for applications where fast response is required or limited computational resources are available.

In comparison, the FK model (Kalman filter with exogenous variables, DKF-ARX-Pt), although achieving an R^2 of 0.976 and an NSE of the same value, showed lower performance on the KGE metric (0.735). This suggests that, although the model can accurately capture the overall trend of the index, it has more difficulty in faithfully representing the dispersion and error structure, especially at short scales such as SPEI1, where its performance was significantly lower (KGE < 0). Nevertheless, the FK model is still useful for long scales (SPEI12 and SPEI24), where its dynamic structure makes it stable and less susceptible to overfitting.

A key aspect in the discussion is the role of the SPEI scale in the performance of the models. It was confirmed that the intermediate scales (SPEI3 to SPEI12) represent the best compromise between sensitivity and predictive stability. The SPEI1 scale, due to its high variability and dependence on very short-term weather events, presented high errors and lower reliability for all models, while SPEI24, although stable, smooths the data too much and may miss critical information on rapid drought events.

As shown in Table 6, the NARX model achieves the lowest average error metrics (MAE and RMSE) and the highest values in R^2 , NSE, and KGE, indicating excellent predictive accuracy on average. However, despite its strong performance, NARX presents challenges in computational demand and occasional instability in training convergence, especially when applied to data-sparse stations or longer SPEI time scales. FK also consistently produced positive KGE and NSE values across nearly all stations, while NARX exhibited performance degradation and instability at short time scales. This justifies our

conclusion that FK is the most reliable model overall, especially for long-term drought forecasting and risk analysis.

In addition, the analysis revealed that models with memory (GRU and NARX) tend to perform better than FK, especially in prediction horizons of 3 to 6 months, which is highly relevant for early warning systems, where changes in water conditions need to be anticipated in time to plan mitigation measures.

4.7 Conclusions

The present comparative analysis of Standardized Precipitation Evapotranspiration Index (SPEI) prediction models at multiple time scales (SPEI1 to SPEI24) and for 3- and 6-month horizons demonstrates key differences in model performance. While the NARX model achieved the best average metrics (the lowest MAE and RMSE, and the highest R^2 , NSE, and KGE), it exhibited instability and higher computational costs, limiting its applicability in real-time or data-scarce contexts.

In contrast, the DKF-ARX-Pt (Kalman filter) model proved to be the most consistent and robust across stations and SPEI scales. It achieved high accuracy (R^2 and NSE > 0.97), low error dispersion, and positive KGE values at almost all scales—especially at medium and long scales such as SPEI6, SPEI12, and SPEI24. Its low computational demand and stable behavior make it highly suitable for early warning systems, drought risk monitoring, and climate adaptation strategies.

GRU showed competitive performance at intermediate scales, with relatively low training complexity, but its performance varied more across stations and lead times. All models struggled to predict SPEI1 reliably, reflecting the challenges of capturing short-term variability in climate systems.

In summary, FK offers the best trade-off between accuracy, generalization, and computational efficiency. While NARX and GRU demonstrate potential, their

practical deployment would require further tuning and computational resources. This study supports the FK model as a strong candidate for operational drought forecasting in Central Mexico, especially under resource-limited or real-time conditions.

4.8 References

- ASCE. (2000). Artificial neural networks in hydrology. I: Preliminary concepts. *J. Hydrol. Eng.*, 5, 115–123.
- Achite, M.; Gul, E.; Elshaboury, N.; Jehanzaib, M.; Mohammadi, B.; Danandeh Mehr, A. (2023). An improved adaptive neuro-fuzzy inference system for hydrological drought prediction in Algeria. *Phys. Chem. Earth*, 131, 103451.
- Agudelo, J.; Guigue, V.; Manfredotti, C.; Piot, H. (2025). Drought forecasting using a hybrid neural architecture for integrating time series and static data. *arXiv* 2025, arXiv:2504.05957. *Water* 2025, 17, 2005 20 of 20
- Ahmad, I.; Tang, D.; Wang, T.; Wang, M.; Wagan, B. (2015). Precipitation trends over time using Mann-Kendall and Spearman's rho tests in Swat River Basin, Pakistan. *Adv. Meteorol.*, 2015, 431860.
- Alkubaisi, H.; Danandeh Mehr, A.; Adarsh, S.; Khan, M.M.H. (2025). Drought modelling and forecasting using shallow and deep machine learning techniques. *Model. Earth Syst. Environ.*, 11, 41.
- Allen, R.G.; Pereira, L.S.; Raes, D.; Smith, M. (1998). Crop evapotranspiration (guidelines for computing crop water requirements). In *FAO Irrigation and Drainage Paper 56*; Food and Agriculture Organization (FAO): Rome, Italy.
- Aviles, A.; Celleri, R.; Solera, A.; Paredes, J. (2016). Probabilistic forecasting of drought events using Markov chain- and Bayesian network-based models: A case study of an Andean regulated river basin. *Water* 2016, 8, 37.
- Beguieria, S.; Vicente, S. (2014). Calculation of the Standardized Precipitation-Evapotranspiration Index. Package SPEI.R for R or RStudio Program.

Available online: <https://cran.r-project.org/web/packages/SPEI/index.html> (accessed on 13 May 2023).

Bergmeir, C.; Benitez, J.M. (2012). On the use of cross-validation for time series predictor evaluation. *Inf. Sci.* 2012, 191, 192–213.

Bergmeir, C.; Hyndman, R.J.; Benitez, J.M. (2018). Bagging exponential smoothing methods using STL decomposition and Box–Cox transformation. *Int. J. Forecast.*, 34, 45–59.

Carrillo-Carrillo, M.; Ibanez-Castillo, L.; Arteaga-Ramirez, R.; Arevalo-Galarza, G. (2025). Spatio-Temporal Analysis of Drought with SPEI in the State of Mexico and Mexico City. *Atmosphere* 2025, 16, 202.

Castillo-Castillo, M.; Ibanez-Castillo, L.; Valdes, J.B.; Arteaga-Ramirez, R. (2017). Analisis de sequias meteorologicas en la cuenca del rio Fuerte, Mexico. *Tecnol. Cienc. Agua* 2017, 8, 35–52.

Cho, K.; Van Merriënboer, B.; Gulcehre, C.; Bahdanau, D.; Bougares, F.; Schwenk, H.; Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv* 2014, arXiv:1406.1078.

Chollet, F.; Guzman-Rivera, A.; Liang, C.; Bushaev, V.; Vasudevan, V.; Komljenovic, D.; Taha, A.; Wenzek, G.; Karpov, I.; Lim, S. Keras. (2015). GitHub Repository. Available online: <https://github.com/keras-team/keras> (accessed on 10 May 2024).

Climate Engine. (2024). Desert Research Institute and University of California, Merced. Version 2.1. 2024. Available online: <http://climateengine.org> (accessed on 7 April 2024).

Dastorani, M.T.; Afkhami, H. (2011). Application of artificial neural networks for regional drought prediction using meteorological drought indices. *Water Resour. Manag.* 2011, 25, 407–426. *Water* 2025, 17, 2005 19 of 20

Ding, Y.; Yu, G.; Tian, R.; Sun, Y. (2022). Application of a Hybrid CEEMD–LSTM Model Based on the Standardized Precipitation Index for Drought

Forecasting: The Case of the Xinjiang Uygur Autonomous Region, China. *Atmosphere* 2022, 13, 1504.

Dominguez-Castro, F. (2022). Future Changes in Tropical Cyclone and EasterlyWave Characteristics over Tropical North America. In *Proceedings of the EGU General Assembly 2022*, Vienna, Austria, 23–27 May 2022; EGU22-851.

Farzin, S.; Valikhan Anaraki, M.; Naeimi, M.; Zandifar, S. (2022). Prediction of the groundwater table and drought analysis: A new hybridization strategy based on the bi-directional long short-term model and the Harris hawk optimization algorithm. *J. Water Clim. Change* 2022, 13, 2233–2254.

Funk, C.; Peterson, P.; Landsfeld, M.; Pedreros, D. (2015a). The climate hazards group infrared precipitation with stations—A new environmental record for monitoring extremes. *Sci. Data* 2015, 2, 150066.

Funk, C.; Verdin, J.; Michaelsen, J.; Peterson, P.; Pedreros, D.; Husak, G. (2015b). A global satellite assisted precipitation climatology. *Earth Syst. Sci. Data* 2015, 7, 275–287.

Gal, Y.; Ghahramani, Z. (2016). Dropout as a Bayesian approximation: Representing model uncertainty in deep learning. In *Proceedings of the 33rd International Conference on Machine Learning*, New York, NY, USA, 19–24 June 2016; pp. 1050–1059.

Gong, Z.; Zhang, L.; Xie, Y.; Li, Y. (2023). Detecting and classifying regional climate change trends using Mann-Kendall analysis and pattern recognition. *Clim. Dyn.* 2023, 60, 33–48.

Gupta, H.V.; Kling, H.; Yilmaz, K.K.; Martinez, G.F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *J. Hydrol.* 2009, 377, 80–91.

Hamed, K.H. (2008). Trend detection in hydrologic data: The Mann–Kendall trend test under the scaling hypothesis. *J. Hydrol.* 2008, 349, 350–363.

- Hasan, N.A.; Dongkai, Y.; Al-Shibli, F. (2023). SPI and SPEI Drought Assessment and Prediction Using TBATS and ARIMA Models, Jordan. *Water* 2023, 15, 3598.
- Hernandez-Vasquez, R.; Ibanez-Castillo, C. (2021). Aplicación de redes neuronales para la predicción de sequias en la cuenca del rio Sonora. *Rev. Hidrometeorol. Apl.* 2021, 12, 45–58.
- Hochreiter, S.; Schmidhuber, J. (1997). Long short-term memory. *Neural Comput.* 1997, 9, 1735–1780.
- Huang, S.; Yu, L.; Luo, W.; Pan, H.; Li, Y.; Zou, Z.; Wang, W.; Chen, J. (2023). Runoff Prediction of Irrigated Paddy Areas in Southern China Based on EEMD–LSTM Model. *Water* 2023, 15, 1704.
- INEGI (Instituto Nacional de Estadística, Geografía e Informática). (2023) 2020 Censo de Población y Vivienda. Mexico. Available online: <https://www.inegi.org.mx/datosabiertos/> (accessed on 10 September 2023).
- Kalman, R.E. (1960). A new approach to linear filtering and prediction problems. *J. Basic Eng.*, 82, 35–45.
- Kendall, M.G. (1975). *Rank Correlation Methods*; Griffin: Chicago, IL, USA.
- Kingma, D.P.; Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv* 2014, arXiv:1412.6980.
- Kobayashi, K.; Salam, M.U. (2000). Comparing simulated and observed values using mean squared deviation and its components. *Agron. J.* 2000, 92, 345–352.
- Kousari, M.R.; Ahani, H.; Nikseresht, K. (2013). Rainfall trends analysis of Iran in the last half of the twentieth century. *Int. J. Climatol.* 2013, 33, 396–409.
- Kuhn, M.; Johnson, K. (2013). *Applied Predictive Modeling*; Springer: Berlin/Heidelberg, Germany.

- Lakshminarayanan, B.; Pritzel, A.; Blundell, C. (2017). Simple and scalable predictive uncertainty estimation using deep ensembles. *Adv. Neural Inf. Process. Syst.*, 30, 6402–6413.
- Legates, D.R.; McCabe, G.J. (1999). Evaluating the use of ‘goodness-of-fit’ measures in hydrologic and hydroclimatic model validation. *Water Resour. Res.* 1999, 35, 233–241.
- Lin, T.; Horne, B.G.; Tino, P.; Giles, C.L. (1996). Learning long-term dependencies in NARX recurrent neural networks. *IEEE Trans. Neural Netw.* 1996, 7, 1329–1338.
- Maidment, R.; Grimes, D.; Black, E.; Tarnavsky, E.; Young, M.; Greatrex, H.; Allan, R.P.; Stein, T.; Nkonde, E.; Senkunda, S.; et al. (2017). A new, long-term daily satellite-based rainfall dataset for operational monitoring in Africa. *Sci. Data* 2017, 4, 170063.
- Mann, H.B. (1945). Nonparametric tests against trend. *Econometrica*, 13, 245–259.
- Martínez-Austria, P.; Patino-Gómez, C. (2012). *Vulnerabilidad de México Ante el Cambio Climático: Retos y Prioridades*; Instituto Mexicano de Tecnología del Agua: Morelos, México.
- Marusov, A.; Grabar, V.; Maximov, Y.; Sotiriadi, N.; Bulkin, A.; Zaytsev, (2023). A. Long-term drought prediction using deep neural networks based on geospatial weather data. *Environ. Model. Softw.*, 179, 106127.
- McKee, T.B.; Doesken, N.J.; Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In *Proceedings of the Eight Conference on Applied Climatology*, Anaheim, CA, USA, 17–22 January 1993; American Meteorological Society: Boston, MA, USA; pp. 179–184.
- Melchor Varela, J. A.; Ramirez Hernandez, J.I. (2024). Prediction of hydrological drought by the Standardized Precipitation Evapotranspiration Index in Chihuahua, Mexico, using machine learning algorithms. *Atmosfera* 2024, 38, 687–697.

- Mishra, A.K.; Singh, V.P. (2011). Drought modeling—A review. *J. Hydrol.* 2011, 403, 157–175.
- Moradkhani, H.; Hsu, K.-L.; Gupta, H.V.; Sorooshian, S. (2005). Uncertainty assessment of hydrologic model states and parameters: Sequential data assimilation using the particle filter. *Water Resour. Res.* 2005, 41, W05012.
- Nafii, A.; Taleb, A.; El Mesbahi, M.; Ezzaouini, M.A.; El Bilali, A. (2023). Early Forecasting Hydrological and Agricultural Droughts in the Bouregreg Basin Using a Machine Learning Approach. *Water* 2023, 15, 122.
- Nash, J.E.; Sutcliffe, J.V. (1970). River flow forecasting through conceptual models Part I—A discussion of principles. *J. Hydrol.* 1970, 10, 282–290.
- Son, N.T.; Chen, C.F.; Chen, C.R.; Minh, V.Q. (2021). Identifying climate change hotspots using trend analysis of temperature and precipitation in Vietnam. *Sci. Total Environ.* 2021, 753, 141770.
- Srivastava, N.; Hinton, G.; Krizhevsky, A.; Sutskever, I.; Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.* 2014, 15, 1929–1958.
- Tashman, L.J. (2000). Out-of-sample tests of forecasting accuracy: An analysis and review. *Int. J. Forecast.* 2000, 16, 437–450.
- Terlouw, K.; van de Giesen, N.; Hut, R. (2021). Validation of CHIRPS precipitation data in Ghana. *Hydrol. Earth Syst. Sci.* 2021, 25, 17–30.
- Thorntwaite, C.W. (1948). An approach toward a rational classification of climate. *Geogr. Rev.*, 38, 55–94.
- Thornton, M.M.; Shrestha, R.; Wei, Y.; Thornton, P.E.; Kao, S.-C.; Wilson, B.E. (2022). Daymet: Daily Surface Weather Data on a 1-km Grid for North America, Version 4 R1; ORNL DAAC: Oak Ridge, TN, USA.
- Tkacz, G.; Hu, S. (1999). Forecasting GDP Growth Using Artificial Neural Networks; Bank of Canada: Ottawa, ON, Canada.

- Vazquez-Rodriguez, D.A.; Guerra-Cobian, V.H.; Bruster-Flores, J.L.; Fonseca, C.R.; Yopez-Rincon, F.D. (2024). Evaluating the performance and applicability of satellite precipitation products over the Rio Grande–San Juan Basin in northeast Mexico. *Atmosphere* 2024, 15, 749.
- Vicente-Serrano, S.M.; Begueria, S.; Lopez-Moreno, J.I. (2010). A Multiscalar Drought Index Sensitive to Global Warming: The Standardized Precipitation Evapotranspiration Index. *J. Clim.* 2010, 23, 1696–1718.
- Willmott, C.J.; Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Clim. Res.* 2005, 30, 79–82.
- Wu, X.; Zhou, J.; Yu, H.; Liu, D.; Xie, K.; Chen, Y.; Hu, J.; Sun, H.; Xing, F. (2021). The Development of a Hybrid Wavelet-ARIMA-LSTM Model for Precipitation Amounts and Drought Analysis. *Atmosphere* 2021, 12, 74.
- Yue, S.; Wang, C.Y. (2002). Regional streamflow trend detection with consideration of hydrologic alterations. *Hydrol. Process.*, 16, 2671–2683.
- Zaytar, M.A.; Amrani, C.E. (2016). Sequence to sequence weather forecasting with long short-term memory recurrent neural networks. *Int. J. Comput. Appl.*, 143, 7–11.
- Zhang, L.; Ren, D.; Yang, X.; Zhang, P. (2016). Application of deep learning in climate prediction: A review. *Adv. Meteorol.*, 2016, 1–11.

5 CONCLUSIÓN GENERAL

El presente trabajo permitió comprender de manera integral la dinámica espaciotemporal de la sequía en el Estado de México y la Ciudad de México, así como evaluar el potencial de distintos modelos predictivos para anticipar este fenómeno. El análisis realizado confirma que, en la zona de estudio, las sequías han aumentado en intensidad y frecuencia en las últimas décadas, particularmente en áreas del oeste del Estado de México y el suroeste de la capital. Este patrón coincide con un incremento significativo de la temperatura, mientras que la precipitación no presenta cambios estadísticamente relevantes, lo que resalta el papel del calentamiento en la intensificación del déficit hídrico.

El uso del índice SPEI en escalas de 1 a 24 meses resultó fundamental para identificar la naturaleza multiescalar de la sequía, diferenciando sus impactos meteorológicos, agrícolas e hidrológicos. La integración de datos satelitales y bases históricas robustas permitió superar limitaciones derivadas de la escasez y heterogeneidad de información meteorológica, aportando una visión más precisa de la variabilidad climática regional.

La comparación de modelos predictivos evidenció que el Filtro de Kalman con variables exógenas presentó la mayor precisión y estabilidad en todas las escalas temporales, seguido por las redes neuronales GRU, que mostraron mejor desempeño en horizontes largos pero alta variabilidad en escalas cortas. Las redes NARX registraron el menor rendimiento, con errores más altos y menor eficiencia en la estimación de valores futuros de SPEI. Estos resultados confirman que los filtros basados en métodos bayesianos constituyen herramientas sólidas para la predicción de sequías en contextos de alta variabilidad climática y con disponibilidad limitada de datos.

En conjunto, los hallazgos de esta investigación reafirman la importancia de integrar métodos de monitoreo multiescalar con modelos predictivos avanzados para fortalecer la gestión hídrica y la planificación adaptativa frente al cambio climático. La adopción de este tipo de herramientas, acompañada de políticas públicas basadas en evidencia, permitirá mejorar la resiliencia de los sistemas

socioeconómicos y ambientales en regiones vulnerables, contribuyendo a la seguridad hídrica y a la sostenibilidad a largo plazo.