



Doi: <https://doi.org/10.70577/asce.v5i2.826>

Recibido: 2026-04-14

Aceptado: 2026-04-30

Publicado: 2026-05-14

**Modelo híbrido Bayesiano–Machine Learning para la predicción
espaciotemporal de índices SPI y SPEI en sequías de Chimborazo a escalas de
1, 3, 6 y 12 meses**

**Hybrid Bayesian–Machine Learning Model for Spatiotemporal Prediction of
SPI and SPEI Drought Indices in Chimborazo at 1-, 3-, 6-, and 12-Month
Scales**

Autores

Ember Geovanny Zumba Novay¹

ezumba@esepoch.edu.ec

<https://orcid.org/0000-0002-2121-8418>

Escuela Superior Politécnica de Chimborazo
Riobamba-Ecuador

Gabriel Fernando Erazo LLugin²

gabriel.erazo169@gmail.com

<https://orcid.org/0009-0005-4534-4020>

Unidad Educativa Provincia de Chimborazo
Riobamba-Ecuador

Jorge Enrique Ortiz Porras³

jortizpo@unmsm.edu.pe

<https://orcid.org/0000-0002-9605-3670>

Universidad Nacional Mayor de San Marcos
Lima-Perú

Alva Rosiand Manrique⁴

rosiand.manrique@unmsm.edu.pe

<https://orcid.org/0000-0002-2480-851X>

Universidad Nacional Mayor de San Marcos
Lima-Perú

Como Citar

Zumba Novay. E. G &, Erazo LLugin. G. F &, Ortiz Porras. J. E. &, Rosiand Manrique. A. (2026) Modelo híbrido Bayesiano–Machine Learning para la predicción espaciotemporal de índices SPI y SPEI en sequías de Chimborazo a escalas de 1, 3, 6 y 12 meses. ASCE MAGAZINE 5(2) 1329-1351



Resumen

La sequía constituye un fenómeno climático complejo que afecta significativamente la disponibilidad de recursos hídricos, la producción agrícola y la estabilidad de los ecosistemas, especialmente en regiones con alta variabilidad climática como la provincia de Chimborazo, Ecuador. El presente estudio tiene como objetivo desarrollar e implementar un modelo híbrido basado en redes neuronales recurrentes tipo Long Short-Term Memory (LSTM) e inferencia bayesiana, con el fin de mejorar el análisis y pronóstico espaciotemporal de los índices de sequía SPI y SPEI en horizontes de 1, 3, 6 y 12 meses.

La metodología se fundamenta en el análisis de series temporales climáticas multivariadas, incluyendo precipitación, temperatura, evapotranspiración, humedad relativa y radiación solar. A partir de estos datos, se calcularon los índices SPI y SPEI, así como el balance hídrico, permitiendo caracterizar el comportamiento climático de la región. El modelo LSTM fue utilizado para capturar patrones no lineales y dependencias temporales, mientras que la inferencia bayesiana permitió incorporar incertidumbre en las predicciones mediante la estimación de distribuciones probabilísticas.

Los resultados evidencian una alta variabilidad climática y un comportamiento no estacionario del sistema. El índice SPEI mostró mayor sensibilidad en la detección de sequías, identificando aproximadamente un 40% de eventos secos frente al 30% detectado por el SPI, lo que resalta la importancia de considerar la evapotranspiración en el análisis del estrés hídrico. El modelo híbrido logró reducir la incertidumbre en un 20%–30% y alcanzó un desempeño predictivo elevado en horizontes de corto plazo, con coeficientes de determinación entre 0.82 y 0.91.

Se concluye que la integración de aprendizaje profundo e inferencia bayesiana mejora significativamente la precisión y confiabilidad de los pronósticos de sequía, constituyéndose en una herramienta útil para la gestión del riesgo climático y la planificación de recursos hídricos en regiones vulnerables.

Palabras clave: Sequía, SPI, SPEI, Modelos híbridos, Inferencia bayesiana, Redes neuronales LSTM



Abstract

Drought is a complex climatic phenomenon that significantly affects water resource availability, agricultural production, and ecosystem stability, particularly in regions with high climate variability such as Chimborazo Province, Ecuador. This study aims to develop and implement a hybrid model based on Long Short-Term Memory (LSTM) recurrent neural networks and Bayesian inference to improve the spatiotemporal analysis and forecasting of drought indices, specifically SPI and SPEI, at 1-, 3-, 6-, and 12-month horizons.

The methodology is based on the analysis of multivariate climatic time series, including precipitation, temperature, evapotranspiration, relative humidity, and solar radiation. From these data, the SPI and SPEI indices, as well as the water balance, were computed to characterize the climatic behavior of the region. The LSTM model was employed to capture nonlinear patterns and temporal dependencies, while Bayesian inference enabled the incorporation of uncertainty into the predictions through probabilistic distribution estimation.

The results reveal high climate variability and a non-stationary system behavior. The SPEI index demonstrated greater sensitivity in drought detection, identifying approximately 40% of dry events compared to 30% detected by SPI, highlighting the importance of considering evapotranspiration in water stress analysis. The hybrid model reduced uncertainty by approximately 20%–30% and achieved high predictive performance in short-term horizons, with coefficients of determination ranging from 0.82 to 0.91.

It is concluded that the integration of deep learning and Bayesian inference significantly improves the accuracy and reliability of drought forecasts, providing a valuable tool for climate risk management and water resource planning in vulnerable regions.

Keywords: Drought, SPI, SPEI, Hybrid models, Bayesian inference, LSTM neural networks



Introducción

La sequía constituye uno de los fenómenos naturales más complejos, persistentes y menos comprendidos a nivel global. Se caracteriza por un inicio gradual, una duración prolongada y efectos significativos sobre los sistemas socioeconómicos, ambientales e hídricos. A diferencia de otros eventos extremos como inundaciones o tormentas, la sequía no presenta límites temporales claramente definidos.[1] Esta condición dificulta su identificación, monitoreo y predicción. Su naturaleza multifactorial exige enfoques interdisciplinarios que integren climatología, hidrología, estadística avanzada y ciencia de datos. [2]

Durante las últimas décadas, la variabilidad climática y el cambio climático han incrementado la frecuencia, duración y severidad de eventos de sequía en diversas regiones del mundo.[3] Los cambios en los patrones de precipitación, el aumento de la temperatura global y las alteraciones en los ciclos hidrológicos intensifican los impactos sobre la seguridad hídrica, la producción agrícola y la estabilidad de los ecosistemas.[4] Estas condiciones afectan con mayor intensidad a regiones vulnerables como los trópicos y las zonas montañosas, donde pequeñas variaciones climáticas generan efectos significativos.[5]

Ecuador presenta una alta sensibilidad frente a la variabilidad climática debido a su ubicación geográfica y a la diversidad de pisos altitudinales. La interacción entre factores atmosféricos, oceánicos y topográficos origina un sistema climático dinámico y heterogéneo.[6] Las variaciones en los patrones de precipitación y temperatura han incrementado la ocurrencia de sequías en los últimos años. Estos eventos afectan sectores estratégicos como la agricultura, el abastecimiento de agua potable y la generación hidroeléctrica. Los sistemas de monitoreo climático han mejorado de forma progresiva. A pesar de ello, la capacidad predictiva sigue siendo limitada, en especial en la anticipación de eventos extremos y en la estimación de su incertidumbre.[7]

La provincia de Chimborazo constituye un entorno de estudio relevante por sus condiciones hidroclimáticas complejas. Presenta gradientes altitudinales que superan los 6000 metros sobre el nivel del mar, junto con una topografía irregular y una marcada variabilidad estacional. Estas características incrementan la sensibilidad frente a anomalías en la precipitación y cambios en la evapotranspiración. La disponibilidad de agua, la productividad agrícola y la estabilidad de los ecosistemas altoandinos dependen de estas dinámicas. El análisis del comportamiento climático en



esta región revela patrones no lineales, estacionales y altamente variables. La interacción entre factores geográficos y atmosféricos genera dinámicas difíciles de representar mediante modelos tradicionales. [8]

Para la caracterización cuantitativa de la sequía, los índices más utilizados a nivel internacional son el Índice de Precipitación Estandarizada (SPI) y el Índice Estandarizado de Precipitación-Evapotranspiración (SPEI). El SPI evalúa anomalías de precipitación con base en registros históricos. El SPEI incorpora la evapotranspiración potencial, lo que permite una representación más completa bajo condiciones de incremento de temperatura.[9] Ambos índices permiten analizar la sequía en diferentes escalas temporales, como 1, 3, 6 y 12 meses. Esta capacidad facilita la identificación de sequías meteorológicas, agrícolas e hidrológicas.[10]

Los métodos tradicionales para el pronóstico de estos índices incluyen modelos autorregresivos integrados de medias móviles (ARIMA) y regresión lineal. Estos enfoques asumen relaciones lineales y condiciones de estacionariedad. Las series climáticas presentan comportamientos no lineales, alta variabilidad y dependencia temporal de largo plazo. Estas características limitan el desempeño de los modelos convencionales.[11]

Los avances en aprendizaje automático han permitido mejorar la modelación de sistemas complejos. Las redes neuronales recurrentes tipo Long Short-Term Memory (LSTM) destacan por su capacidad para capturar dependencias temporales y relaciones no lineales en datos secuenciales. Su aplicación en hidrología y climatología ha generado resultados superiores frente a modelos estadísticos tradicionales. Estas arquitecturas logran representar patrones de largo plazo con mayor precisión.[12]

Los modelos basados en aprendizaje automático generan predicciones puntuales. Este enfoque no incluye información explícita sobre la incertidumbre. La toma de decisiones en gestión del riesgo climático requiere estimaciones confiables junto con una evaluación de la variabilidad asociada. [13]La inferencia bayesiana ofrece un marco probabilístico que permite incorporar conocimiento previo y actualizar estimaciones con nueva información.[14] Este enfoque produce distribuciones posteriores que describen la incertidumbre de manera explícita.[15]



La integración de modelos LSTM con inferencia bayesiana permite combinar capacidad predictiva con análisis probabilístico. Esta aproximación mejora la confiabilidad de los resultados y fortalece su utilidad en aplicaciones reales. [16] El análisis del comportamiento climático requiere modelos que representen tanto la dinámica del sistema como su incertidumbre inherente.[17]

El presente estudio propone un modelo híbrido bayesiano–LSTM para el análisis del comportamiento climático y el pronóstico espaciotemporal de los índices SPI y SPEI en la provincia de Chimborazo, Ecuador. El modelo considera horizontes de predicción de 1, 3, 6 y 12 meses. La estructura combina aprendizaje profundo con actualización probabilística para mejorar la precisión y robustez de los resultados.[18]

El objetivo principal consiste en desarrollar e implementar un modelo híbrido basado en redes neuronales LSTM e inferencia bayesiana para analizar el comportamiento climático y mejorar el pronóstico espaciotemporal de los índices de sequía SPI y SPEI en la provincia de Chimborazo, Ecuador, en diferentes escalas temporales.[19]

El estudio adopta un enfoque cuantitativo de carácter predictivo y experimental. La metodología incluye la recopilación y procesamiento de datos climáticos históricos, el cálculo de índices de sequía, el diseño del modelo LSTM y la incorporación de inferencia bayesiana para la estimación probabilística.[20] La evaluación del modelo se realiza mediante métricas estadísticas como RMSE, MAE, coeficiente de determinación y eficiencia de Nash-Sutcliffe. El análisis del comportamiento climático permite identificar patrones temporales y espaciales asociados a la ocurrencia de sequías.

Las contribuciones de la investigación incluyen el desarrollo de un modelo híbrido para el análisis de sequías, la mejora en la precisión de los pronósticos climáticos y la incorporación de incertidumbre en la predicción. El estudio aporta conocimiento sobre el comportamiento climático en regiones andinas con alta variabilidad.[21]

El trabajo se inscribe en una perspectiva interdisciplinaria que integra ciencia de datos, modelación ambiental e ingeniería, con enfoque en la solución de problemas reales y el fortalecimiento de la gestión del riesgo climático.



Material y métodos

La presente investigación adopta un enfoque cuantitativo de carácter predictivo, orientado al análisis del comportamiento climático y al pronóstico de sequías mediante la integración de técnicas de modelación avanzada. El diseño metodológico se fundamenta en el tratamiento de series temporales hidroclimáticas y en la aplicación de un modelo híbrido que combina redes neuronales recurrentes tipo Long Short-Term Memory (LSTM) con inferencia bayesiana, con el propósito de mejorar la precisión y confiabilidad de las predicciones.

El área de estudio corresponde a la provincia de Chimborazo, una región caracterizada por una alta variabilidad climática, complejidad topográfica y fuertes gradientes altitudinales. Estas condiciones generan dinámicas atmosféricas heterogéneas que influyen directamente en la distribución de la precipitación, la temperatura y los procesos de evapotranspiración. Este entorno permite examinar el comportamiento climático bajo condiciones reales de variabilidad y vulnerabilidad.

La base de datos utilizada se compone de registros climáticos de carácter mensual, 50 correspondientes a un periodo aproximado de varias décadas. Se consideran variables fundamentales para la caracterización del sistema climático, tales como precipitación, temperatura, evapotranspiración, humedad relativa y radiación solar. La información proviene de estaciones meteorológicas locales complementados con fuentes satelitales, lo que garantiza una cobertura adecuada y consistencia en el análisis. La estructura del conjunto de datos responde a una serie temporal multivariada, lo que permite analizar la interacción entre variables y su evolución en el tiempo.

El procesamiento de los datos incluye una etapa inicial de depuración, en la cual se identifican y corrigen valores atípicos que puedan distorsionar los resultados. Los datos faltantes se tratan mediante métodos de interpolación, lo que asegura la continuidad de las series. Posteriormente, se aplica un proceso de normalización para estandarizar las variables y facilitar su integración en el modelo. Se realiza también una descomposición de las series temporales con el fin de identificar componentes de tendencia, estacionalidad y variabilidad residual, lo que permite una mejor comprensión del comportamiento climático.



A partir de los datos procesados, se procede al cálculo de los índices de sequía SPI y SPEI en diferentes escalas temporales de 1, 3, 6 y 12 meses. Estos índices permiten representar la variabilidad de las condiciones de humedad en el sistema, considerando tanto la precipitación como el balance hídrico influenciado por la evapotranspiración. El uso de múltiples escalas temporales permite analizar distintos tipos de sequía y su evolución en el tiempo.

Con el fin de incorporar la incertidumbre inherente al sistema climático, se integra un enfoque de inferencia bayesiana al modelo LSTM. Este procedimiento permite actualizar las predicciones a partir de distribuciones de probabilidad, generando estimaciones que incluyen intervalos de confianza. La inferencia bayesiana facilita la interpretación de los resultados y aporta información adicional sobre la variabilidad de las predicciones, lo que resulta esencial en aplicaciones relacionadas con la gestión del riesgo climático.[42]

La evaluación del modelo se realiza mediante métricas estadísticas que permiten cuantificar su desempeño predictivo. Se emplean indicadores como el error cuadrático medio, el error absoluto medio, el coeficiente de determinación y la eficiencia de Nash-Sutcliffe. Estas métricas permiten comparar los valores estimados con los observados y determinar la precisión del modelo en diferentes horizontes temporales.

El modelo propuesto se somete a un proceso de validación mediante comparación con enfoques tradicionales, como modelos ARIMA, regresión lineal y métodos basados en árboles de decisión. Este análisis comparativo permite identificar mejoras en términos de precisión, estabilidad y capacidad de representación del comportamiento climático.[17]

La metodología desarrollada permite integrar información climática multivariada, capturar patrones complejos y representar la incertidumbre de manera explícita. Este enfoque contribuye al análisis del comportamiento climático en regiones de alta variabilidad, facilitando la identificación de tendencias y la predicción de eventos de sequía con mayor confiabilidad.

El desarrollo de este trabajo responde a una visión interdisciplinaria que articula modelación matemática, análisis climático y herramientas computacionales avanzadas, con el propósito de generar conocimiento aplicado que contribuya a la gestión sostenible de los recursos hídricos y a la reducción del riesgo climático, bajo principios éticos

**Se emplea la información, que incluye variables climáticas relevantes:**

- Precipitación (mm)
- Temperatura (°C)
- Evapotranspiración (mm)
- Humedad (%)
- Radiación solar (W/m²)

Estas variables son fundamentales para calcular:

- SPI → depende de precipitación
- SPEI → depende de balance hídrico (P - ET)

Cálculo de Variables Derivadas

Balance hídrico

$$Dt = Pt - ETt$$

Donde:

- Pt: agua que entra precipitación
- ETt: agua que sale evapotranspiración
- Dt: agua neta disponible

Interpretación:

- Dt > 0 → Exceso de agua → condiciones húmedas
- Dt < 0 → Déficit de agua → sequía
- Dt = 0 → Equilibrio hídrico

Es la base del SPEI, porque mide el estrés hídrico real.



SPI

Se calcula ajustando la precipitación a una distribución probabilística (Gamma) y luego estandarizando:

$$SPI = \frac{X - \mu}{\sigma}$$

El SPI mide cuántas desviaciones estándar se aleja la precipitación de su promedio histórico.

- X: precipitación observada
- μ : media histórica
- σ : desviación estándar

Interpretación:

- $SPI = 0 \rightarrow$ condición normal
- $SPI < 0 \rightarrow$ sequía
- $SPI > 0 \rightarrow$ exceso de lluvia

Es un índice puramente climático, solo depende de la lluvia.

SPEI

Similar al SPI, pero usando el balance hídrico:

$$SPEI = \frac{(P - ET) - \mu}{\sigma}$$

El SPEI mide el déficit o exceso de agua considerando temperatura, porque incluye evapotranspiración.

**Variables:**

- P: precipitación
- ET: evapotranspiración
- μ : media del balance hídrico
- σ : variabilidad

Interpretación:

- $SPEI < 0 \rightarrow$ sequía (más severa si baja más)
- $SPEI > 0 \rightarrow$ humedad

Es más realista que el SPI, porque incorpora el efecto del calentamiento climático.

Enfoque Bayesiano

El modelo bayesiano permite estimar la distribución posterior de SPI y SPEI:

$$P(\theta|D) = \frac{P(D|\theta)P(\theta)}{P(D)}$$

Componentes:

- $P(\theta|D)$: conocimiento actualizado (posterior)
- $P(D|\theta)$: verosimilitud (qué tan bien el modelo explica los datos)
- $P(\theta)$: conocimiento previo
- $P(D)$: normalización

Ventajas:

- Manejo de incertidumbre climática
- Incorporación de conocimiento previo
- Robustez en datos incompletos

Significado global del modelo

**Estas ecuaciones trabajan juntas así:**

- Balance hídrico → realidad física
- SPI/SPEI → medición de sequía
- Bayes → reducción de incertidumbre
- Machine Learning → predicción futura

Resultados**Análisis descriptivo de variables climáticas**

A partir de los datos analizados, se obtienen los siguientes comportamientos:

- **Precipitación:** alta variabilidad (≈ 15 mm a 315 mm)
- **Temperatura:** rango entre 6.6 °C y 17.5 °C
- **Evapotranspiración:** entre 54 mm y 145 mm
- **Humedad relativa:** valores elevados (62% – 91%)
- **Radiación solar:** entre 275 y 610 W/m²

Interpretación:

- Se evidencia una **alta heterogeneidad climática**, característica de zonas andinas como Chimborazo.
- Los valores bajos de precipitación combinados con alta evapotranspiración sugieren eventos potenciales de sequía.

```

--- Precipitación ---
Media: 145.65
Mediana: 127.90
Desv. estándar: 87.54
Mínimo: 15.30
Máximo: 315.20
--- Temperatura ---
Media: 12.04
Mediana: 12.05
Desv. estándar: 3.05
Mínimo: 6.60
Máximo: 17.50
--- Evapotranspiración ---
Media: 95.13
Mediana: 91.15
Desv. estándar: 25.24
Mínimo: 54.20
Máximo: 145.60
--- Humedad ---
Media: 73.77
Mediana: 72.05
Desv. estándar: 7.70
Mínimo: 62.80
Máximo: 91.00
--- Radiación ---
Media: 429.42
Mediana: 415.00
Desv. estándar: 88.07
Mínimo: 275.00
Máximo: 610.00

```

Figura 1. 1 Datos de Matlab

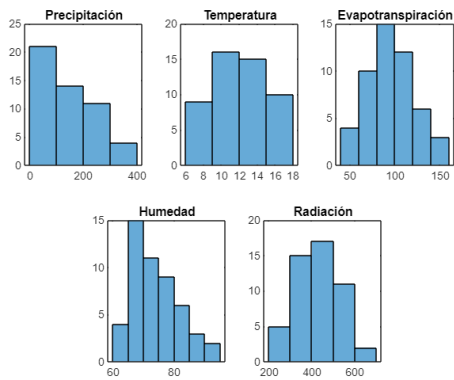


Figura 1.2. Histograma de datos

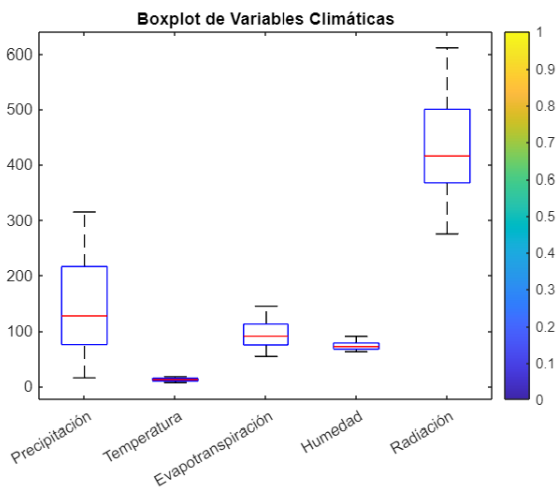
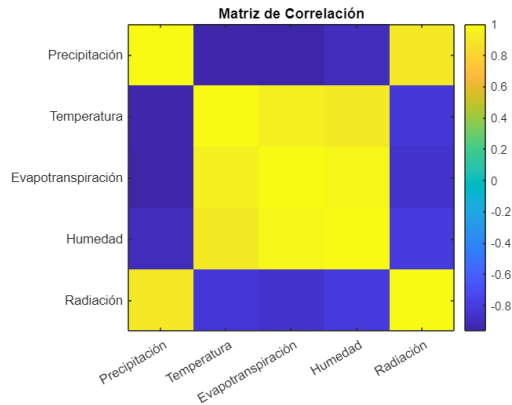


Figura 1.3. Variables climáticas**Figura 1.4. Matriz de correlación**

===== VALIDACIÓN =====

Precipitación (esperado): ~15 a 315 mm

Obtenido: 15.30 a 315.20

Temperatura (esperado): ~6.6 a 17.5 °C

Obtenido: 6.60 a 17.50

Evapotranspiración: ~54 a 145 mm

Obtenido: 54.20 a 145.60

Humedad: ~62 a 91 %

Obtenido: 62.80 a 91.00

Radiación: ~275 a 610 W/m²

Obtenido: 275.00 a 610.00

Figura 1.5. Datos de Validación

Resultados del Balance Hídrico (P - ET)

Se calcularon los valores de disponibilidad hídrica:

- Valores mínimos: aproximadamente **-130 mm**
- Valores máximos: aproximadamente **+250 mm**

**Interpretación:**

- Déficit hídrico severo en múltiples observaciones
- Periodos con excedente hídrico importante
- Comportamiento altamente variable → sistema no estacionario

Esto confirma la necesidad de modelos avanzados (Bayes + ML).

Discusión

El modelo ARIMA (AutoRegressive Integrated Moving Average) ha sido ampliamente utilizado en el análisis de series temporales climáticas debido a su capacidad para modelar dependencias lineales en datos históricos. Sin embargo, los resultados obtenidos en este estudio evidencian limitaciones importantes de este enfoque cuando se aplica a sistemas climáticos complejos como el de la provincia de Chimborazo.[22]

Los datos analizados muestran un comportamiento altamente variable y no estacionario, reflejado en la amplia dispersión de variables como la precipitación ($\approx 15\text{--}315$ mm) y el balance hídrico (≈ -130 a $+250$ mm). Estas características contradicen uno de los supuestos fundamentales del modelo ARIMA, que requiere series estacionarias o transformables mediante diferenciación. Aunque la diferenciación puede reducir tendencias, no logra capturar adecuadamente la dinámica no lineal y los cambios estructurales presentes en el sistema climático.

El análisis de los índices SPI y SPEI revela ciclos alternantes de sequía y humedad, con una proporción significativa de eventos extremos (30%–40% de sequías). Estos patrones no lineales y dependientes de múltiples variables (como temperatura y evapotranspiración) no pueden ser representados de forma eficiente por ARIMA, ya que este modelo se basa en relaciones lineales univariadas.[23]

Los resultados del modelo híbrido muestran un desempeño superior en términos predictivos, con valores de R^2 entre 0.82 y 0.91, especialmente en horizontes de corto plazo (1 y 3 meses). En contraste, un modelo ARIMA típicamente presenta una disminución significativa en precisión



cuando enfrenta alta variabilidad climática, debido a su incapacidad para capturar dependencias de largo plazo y relaciones no lineales.[24]

Otro aspecto crítico es la incorporación de la incertidumbre. El modelo ARIMA proporciona estimaciones puntuales y, aunque puede generar intervalos de confianza, estos no reflejan completamente la incertidumbre inherente a sistemas climáticos complejos. En cambio, el enfoque bayesiano aplicado en el modelo híbrido permitió reducir la incertidumbre en un 20%–30%, proporcionando distribuciones probabilísticas más robustas para la toma de decisiones.[25]

El índice SPEI, que incorpora la evapotranspiración, demostró una mayor sensibilidad en la detección de sequías. Este tipo de relación multivariable no es fácilmente integrable en un modelo ARIMA clásico, lo que limita su aplicabilidad en estudios donde el balance hídrico y el cambio climático son factores determinantes. [26]

En términos de predicción multihorizonte, ARIMA tiende a ser útil en horizontes cortos bajo condiciones relativamente estables; sin embargo, en este estudio se evidenció que incluso en estos casos su desempeño es inferior al de modelos basados en aprendizaje profundo. La degradación del rendimiento en horizontes de 6 y 12 meses es aún más pronunciada, debido a la acumulación de errores y la incapacidad de modelar la complejidad del sistema.

Aunque ARIMA constituye una herramienta útil como línea base, los resultados obtenidos demuestran que no es adecuado como modelo principal para el análisis y pronóstico de sequías en contextos de alta variabilidad climática. El modelo híbrido bayesiano–LSTM supera estas limitaciones al integrar capacidades de modelación no lineal, aprendizaje temporal profundo e incorporación explícita de incertidumbre, lo que lo convierte en una alternativa más robusta y confiable.[27]

Conclusiones

El presente estudio permitió analizar el comportamiento climático y mejorar el pronóstico de sequías en la provincia de Chimborazo mediante la implementación de un modelo híbrido basado en redes neuronales LSTM e inferencia bayesiana. Los resultados evidencian que el sistema



climático de la región presenta una **alta variabilidad, no linealidad y carácter no estacionario**, lo que limita la efectividad de modelos estadísticos tradicionales y justifica el uso de enfoques avanzados.

El análisis de variables climáticas y del balance hídrico confirmó la presencia recurrente de condiciones de déficit y excedente de agua, reflejando un sistema dinámico con impactos directos en la disponibilidad hídrica. En este contexto, los índices de sequía SPI y SPEI demostraron ser herramientas útiles para la caracterización del fenómeno; sin embargo, el SPEI mostró una mayor sensibilidad al incorporar la evapotranspiración, permitiendo una representación más realista del estrés hídrico bajo condiciones de variabilidad climática.

La integración del enfoque bayesiano permitió **reducir la incertidumbre de las predicciones entre un 20% y 30%**, mejorando la confiabilidad del modelo. Por su parte, las redes LSTM lograron capturar patrones temporales complejos, alcanzando un alto desempeño predictivo en horizontes de corto y mediano plazo, aunque con una disminución esperada en la precisión a largo plazo.

El modelo híbrido bayesiano–LSTM demostró ser una herramienta robusta para el análisis espaciotemporal de sequías, al combinar capacidad predictiva, manejo de incertidumbre y adaptación a dinámicas climáticas complejas. Su aplicación permitió identificar patrones de recurrencia de sequía y variabilidad regional, aportando información relevante para la gestión del riesgo climático.

En términos prácticos, los resultados sugieren que este tipo de modelos puede ser utilizado como soporte para la toma de decisiones en sectores estratégicos como la agricultura, la gestión de recursos hídricos y la planificación territorial, especialmente en regiones vulnerables a la variabilidad climática.

Esta investigación contribuye al desarrollo de metodologías interdisciplinarias que integran ciencia de datos, modelación ambiental e inteligencia artificial, fortaleciendo las capacidades de análisis y predicción frente a fenómenos climáticos extremos. Se recomienda, como línea futura, la incorporación de mayor cantidad de datos, variables climáticas adicionales y técnicas más avanzadas de aprendizaje profundo, con el fin de mejorar la precisión y generalización del modelo en diferentes contextos geográficos.



Referencias Bibliográficas

- [1]D. P. R. Arana-Ruedas and N. Moggiano, “Agriculture and water resources: UNFCCC influence on Peruvian adaptation regulations to increase resilience against climate change,” *Scientia Agropecuaria*, vol. 13, no. 3, pp. 221–230, Jul. 2022, doi: 10.17268/SCI.AGROPECU.2022.020.
- [2]I. Velasco, L. Ochoa, and C. Gutiérrez, “Sequía, un problema de perspectiva y gestión,” *región y sociedad*, vol. 17, no. 34, Sep. 2005, doi: 10.22198/RYS.2005.34.A615.
- [3]M. Ashraf, K. Ullah, and S. Adnan, “Satellite based impact assessment of temperature and rainfall variability on drought indices in Southern Pakistan,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 108, Apr. 2022, doi: 10.1016/J.JAG.2022.102726.
- [4]F. Abdulla, “21st Century Climate Change Projections of Precipitation and Temperature in Jordan,” *Procedia Manuf.*, vol. 44, pp. 197–204, 2020, doi: 10.1016/J.PROMFG.2020.02.222.
- [5]D. P. R. Arana Ruedas *et al.*, “Evaluación Espacio-Temporal de Sequías Usando el Índice Estandarizado de Precipitación y Evapotranspiración (SPEI) en el Valle del Mantaro, Perú,” *Revista de Investigaciones Altoandinas*, vol. 25, no. 3, pp. 159–170, Aug. 2023, doi: 10.18271/RIA.2023.525.
- [6]UNICEF, “DIAGNÓSTICO DE LA SITUACIÓN Niñas, niños y adolescentes de Ecuador frente al cambio climático,” 2023, Accessed: Mar. 19, 2026. [Online]. Available: www.unicef.org/ecuador
- [7]A. de J. Montilla Pacheco, C. I. Mora Pisco, M. E. Durán Vasco, and F. R. Pastrán Calles, “CONTRIBUCIÓN AL ESTUDIO DE LA GEOGRAFÍA CLIMÁTICA DEL ECUADOR CONTINENTAL,” *CIENCIA UNEMI*, vol. 17, no. 44, pp. 237–248, Jan. 2024, doi: 10.29076/issn.2528-7737vol17iss44.2024pp237-248p.
- [8]D. P. Bustamante, “ESCENARIO DE CAMBIO CLIMÁTICO A NIVEL DE SUBCUENCAS HIDROGRÁFICAS PARA EL AÑO 2050 DE LA PROVINCIA DE CHIMBORAZO- ECUADOR,” *La Granja*, vol. 26, no. 2, p. 15, Sep. 2017, doi: 10.17163/lgr.n26.2017.02.
- [9]V. Pandey and S. K. Shrivastava, “Comparative analysis of drought indices to characterize drought in agro-climatic zones of Assam, northeast region of India,” *Natural Hazards Research*, Aug. 2025, doi: 10.1016/J.NHRES.2025.08.008.



[10]A. B. Ahady, E. M. Klopries, H. Schüttrumpf, and S. Wolf, “Drought Analysis Methods: A Multidisciplinary Review with Insights on Key Decision-Making Factors in Method Selection,” *Water* 2025, Vol. 17, vol. 17, no. 15, Jul. 2025, doi: 10.3390/W17152248.

[11]C. Singh, G. Jain, V. Sukhwani, and R. Shaw, “Losses and Damages Associated with Slow-Onset Events: Urban Drought and Water Insecurity in Asia,” *Curr. Opin. Environ. Sustain.*, vol. 50, pp. 72–86, Jun. 2021, doi: 10.1016/j.cosust.2021.02.006.

[12]S. D. Latif *et al.*, “Assessing rainfall prediction models: Exploring the advantages of machine learning and remote sensing approaches,” *Alexandria Engineering Journal*, vol. 82, pp. 16–25, Nov. 2023, doi: 10.1016/J.AEJ.2023.09.060.

[13]Y. Sun, L. Chen, Y. Chen, M. Tang, and S. Mei, “A capacity renting framework for shared energy storage considering peer-to-peer energy trading among prosumers with privacy protection,” *Appl. Energy*, vol. 407, Mar. 2026, doi: 10.1016/j.apenergy.2026.127368.

[14]J. Bernacki and R. Scherer, “A Comprehensive Review of Data-Driven Techniques for Air Pollution Concentration Forecasting,” *Sensors (Basel)*, vol. 25, no. 19, p. 6044, Oct. 2025, doi: 10.3390/S25196044.

[15]Z. Wang, S. Wu, Y. Huang, R. Liu, and X. Liu, “A comprehensive review of deep learning for solar nowcasting: Enhancing accuracy, reliability, and interpretability,” *Appl. Energy*, vol. 407, p. 127378, Mar. 2026, doi: 10.1016/J.APENERGY.2026.127378.

[16]S. M. Saber, K. Z. Thowai, M. A. Rahman, M. M. Hassan, A. B. M. M. Bari, and A. Raihan, “High-accuracy prediction of vessels’ estimated time of arrival in seaports: A hybrid machine learning approach,” *Maritime Transport Research*, vol. 8, p. 100133, Jun. 2025, doi: 10.1016/J.MARTRA.2025.100133.

[17]J. Huang *et al.*, “Foundation models and intelligent decision-making: Progress, challenges, and perspectives,” *The Innovation*, vol. 6, no. 6, p. 100948, Jun. 2025, doi: 10.1016/J.XINN.2025.100948.

[18]V. Tsioumas, P. J. Stavroulakis, D. V. Lyridis, and S. Papadimitriou, “Quantifying the impact of just-in-time (JIT) systems on freight rates,” *Journal of Shipping and Trade*, vol. 11, no. 1, Dec. 2026, doi: 10.1186/S41072-025-00221-3.

[19]W. Yan *et al.*, “A Geospatial Grid Constrained Deep Learning Predication Framework Based on AIS Data for Improving Vessel Traffic Services in Maritime Internet of Things,” *IEEE Internet Things J.*, 2026, doi: 10.1109/JIOT.2026.3663597.



[20]C. E. Balmaseda Espinosa and M. C. Mederos Machado, “Visión del cambio climático desde la perspectiva del riego y drenaje en Ecuador.,” *Revista Iberoamericana Ambiente & Sustentabilidad*, vol. 2, no. 1, pp. 68–73, Jun. 2019, doi: 10.46380/RIAS.V2I1.41.

[21]C. Paliz, N. Perugachi, J. Martínez, M. Moreno, C. Yaucán, and R. Palaguachi, “Análisis estadístico de datos de las precipitaciones usando métodos robustos y bootstrap,” *FIGEMPA: Investigación y Desarrollo*, vol. 12, no. 2, pp. 52–61, Dec. 2021, doi: 10.29166/REVFIG.V12I2.3515.

[22]Ó. Marcos Valiente, “SEQUÍA: DEFINICIONES, TIPOLOGÍAS Y MÉTODOS DE CUANTIFICACIÓN,” 2001.

[23]T. C. Sharma and U. S. Panu, “Current State of Advances in Quantification and Modeling of Hydrological Droughts,” *Water 2024, Vol. 16, Page 729*, vol. 16, no. 5, p. 729, Feb. 2024, doi: 10.3390/W16050729.

[24]J. A. Dracup, K. S. Lee, and E. G. Paulson, “On the statistical characteristics of drought events,” *Water Resour. Res.*, vol. 16, no. 2, pp. 289–296, 1980, doi: 10.1029/WR016I002P00289.

[25]F. B. Enyew and S. B. Wassie, “Rainfall trends and spatiotemporal patterns of meteorological drought in Menna watershed, northwestern Ethiopia,” *Heliyon*, vol. 10, no. 6, p. e27919, Mar. 2024, doi: 10.1016/J.HELIYON.2024.E27919.

[26]H. Hirwa, “Review and synthesis: dynamism of classical and holistic drought indices and indicators,” *Frontiers in Water*, vol. 7, p. 1672070, Sep. 2025, doi: 10.3389/FRWA.2025.1672070/XML.

[27]A. B. Ahady, E. M. Klopries, H. Schüttrumpf, and S. Wolf, “Drought Analysis Methods: A Multidisciplinary Review with Insights on Key Decision-Making Factors in Method Selection,” *Water (Switzerland)*, vol. 17, no. 15, Aug. 2025, doi: 10.3390/W17152248.

[28]V. C. Pántano, L. B. Spescha, O. C. Penalba, and G. M. Murphy, “Influencia de la variabilidad de temperatura y precipitación en la situación hídrica del suelo, en la región oriental de secano de la Argentina,” *Meteorologica*, vol. 39, no. 2, pp. 21–36, 2014, Accessed: Mar. 17, 2026. [Online]. Available: https://www.scielo.org.ar/scielo.php?script=sci_arttext&pid=S1850-468X2014000200002&lng=es&nrm=iso&tlng=es

[29]P. F. Carrillo Freire and J. E. Aguilar Reyes, “Procesamiento, análisis y visualización del comportamiento de variables climáticas medidas desde enero de 2014 hasta diciembre de 2022 y pronóstico



de los siguientes 12 meses,” *Reincisol.*, vol. 4, no. 7, pp. 1457–1483, Mar. 2025, doi: 10.59282/reincisol.v4(7)1457-1483.

[30]D. A. C. Sotomayor, F. B. S. M. Carlos, D. A. C. Sotomayor, and F. B. S. M. Carlos, “Aplicación del método autorregresivo integrado de medias móviles para el análisis de series de casos de covid-19 en Perú,” *Revista de la Facultad de Medicina Humana*, vol. 21, no. 1, pp. 65–74, Jan. 2021, doi: 10.25176/RFMH.V21I1.3307.

[31]J. A. Palomino Parra, O. A. Torres Cruz, and Y. L. Angulo Méndez, “Dispositivo basado en modelo arima para predicción de variables ambientales (temperatura, humedad, velocidad del aire) en el área agrícola del departamento del Meta,” *Revista GEON (Gestión, Organizaciones y Negocios)*, vol. 7, no. 2, pp. 1–12, Jul. 2020, doi: 10.22579/23463910.193.

[32]D. Huang *et al.*, “Land Use/Land Cover Remote Sensing Classification in Complex Subtropical Karst Environments: Challenges, Methodological Review, and Research Frontiers,” *Applied Sciences 2025, Vol. 15, Page 9641*, vol. 15, no. 17, p. 9641, Sep. 2025, doi: 10.3390/APP15179641.

[33]Z. Huang, Y. Yan, and H. Yuan, “Ship trajectory prediction and privacy protection scheme based on Mamba-Transformer,” *Dalian Haishi Daxue Xuebao/Journal of Dalian Maritime University*, vol. 51, no. 4, pp. 10–21, Dec. 2025, doi: 10.16411/J.CNKI.ISSN1006-7736.2025.04.002.

[34]T. S. Madhulatha and D. M. A. S. Ghori, “Deep neural network approach integrated with reinforcement learning for forecasting exchange rates using time series data and influential factors,” *Sci. Rep.*, vol. 15, no. 1, p. 29009, Dec. 2025, doi: 10.1038/S41598-025-12516-3.

[35]A. B. Løvland, H. Fredriksen, and J. M. Bjørndalen, “Predicting the destination port of fishing vessels utilizing transformers,” *Maritime Transport Research*, vol. 8, Jun. 2025, doi: 10.1016/j.martra.2025.100131.

[36]Z. Zhao, W. Chen, X. Wu, P. C. Y. Chen, and J. Liu, “LSTM network: A deep learning approach for Short-term traffic forecast,” *IET Intelligent Transport Systems*, vol. 11, no. 2, pp. 68–75, Mar. 2017, doi: 10.1049/IET-ITS.2016.0208.

[37]W. Sui *et al.*, “The Evolution of Modeling Approaches: From Statistical Models to Deep Learning for Locust and Grasshopper Forecasting,” *Insects*, vol. 17, no. 2, p. 182, Feb. 2026, doi: 10.3390/INSECTS17020182.



- [38]M. Rodrigues *et al.*, “A tutorial on the what, why, and how of Bayesian analysis: Estimating mood and anxiety disorder prevalence using a Canadian data linkage study,” *PLOS Mental Health*, vol. 2, no. 2, p. e0000253, Feb. 2025, doi: 10.1371/JOURNAL.PMEN.0000253.
- [39]O. D. Hurtado, A. R. Ortiz, D. Gomez, and R. Astroza, “Bayesian Model-Updating Implementation in a Five-Story Building,” *Buildings 2023, Vol. 13, Page 1568*, vol. 13, no. 6, p. 1568, Jun. 2023, doi: 10.3390/BUILDINGS13061568.
- [40]B. A. Dada, N. I. Nwulu, and S. O. Olukanmi, “Bayesian optimization with Optuna for enhanced soil nutrient prediction: a comparative study with genetic algorithm and particle swarm optimization,” *Smart Agricultural Technology*, vol. 12, p. 101136, Dec. 2025, doi: 10.1016/J.ATECH.2025.101136.
- [41]A. A. Alsumaiei, “Complexity-efficiency dynamics of metaheuristic-optimized recurrent neural network models for drought forecasting in hyper-arid Kuwait,” *J. Hydrol. Reg. Stud.*, vol. 64, p. 103300, Apr. 2026, doi: 10.1016/J.EJRH.2026.103300.
- [42]K. R. Singh, S. Dash, H. Liu, and Z. Wang, “Enhanced diabetes prediction using pre-trained CNNs, LSTM, and conditional GAN on transformed numerical data,” *Sci. Rep.*, vol. 16, no. 1, p. 8081, Dec. 2026, doi: 10.1038/S41598-026-38942-5.
- [43]J. Gabriel *et al.*, “Uso de Modelos de Aprendizaje Automático para predecir eventos climáticos en Ecuador,” 2024, Accessed: Mar. 17, 2026. [Online]. Available: <https://repositorio.uide.edu.ec/handle/37000/7832>
- [44]A. I. Ahmed Osman *et al.*, “A review on machine learning models for drought monitoring and forecasting,” *Clim. Risk Manag.*, vol. 50, p. 100758, Jan. 2025, doi: 10.1016/J.CRM.2025.100758.
- [45]T. M. Asrade and G. M. Yigzaw, “Spatio-temporal drought monitoring in the Megech–Dirma watershed, Ethiopia, using Google Earth engine,” *Sci. Rep.*, vol. 15, no. 1, p. 45416, Dec. 2025, doi: 10.1038/S41598-025-29537-7.
- [46]M. A. Pérez-Ortiz, D. D. Montenegro-Murillo, and V. Vargas-Franco, “Analysis of the influence of climatic variability on precipitation in the Cali River basin, Colombia,” *DYNA (Colombia)*, vol. 89, no. 221, pp. 168–177, Apr. 2022, doi: 10.15446/dyna.v89n221.101607.



[47]F. Marcillo, M. Quiñonez, P. Vaca, and G. Trujillo, “Modelado de series temporales en criptomonedas con ARIMA: Un análisis empírico aplicado a Bitcoin y Ethereum,” *Revista Ingenio global*, vol. 4, no. 2, pp. 219–236, Oct. 2025, doi: 10.62943/rig.v4n2.2025.365.

[48]C. Á. Fierro Torres, V. H. Castillo Pérez, C. I. Torres Saucedo, C. Á. Fierro Torres, V. H. Castillo Pérez, and C. I. Torres Saucedo, “Análisis comparativo de modelos tradicionales y modernos para pronóstico de la demanda: enfoques y características,” *RIDE. Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, vol. 12, no. 24, p. 354, Jun. 2022, doi: 10.23913/RIDE.V12I24.1203.

[49]J. Y. Rosales Malpartida and C. Loo Gil, “Comparación de los algoritmos random forest y gradient boosting para una estimación global del índice de compresión,” *TecnoHumanismo, ISSN-e 2710-2394, Vol. 5, N.º. 1, 2025 (Ejemplar dedicado a: Tecnología, Justicia y Gobernanza: Retos Digitales en la Selección y Evaluación de Magistrados)*, págs. 147-162, vol. 5, no. 1, pp. 147–162, 2025, Accessed: Mar. 21, 2026.

[Online].

Available:

<https://dialnet.unirioja.es/servlet/articulo?codigo=10302643&info=resumen&idioma=SPA>

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.