

MODELO ANFIS PARA PREDICCIÓN DEL CLIMA EN LOS VALLES DE QUITO, ECUADOR

LEONARDO DAVID RUIZ AGUIRRE Y
MARÍA FERNANDA CAIZATO CHULCA

RESUMEN

La predicción de variables climáticas constituye un desafío debido a la naturaleza no lineal y variable de los sistemas atmosféricos, particularmente en regiones andinas como los valles de Quito, Ecuador. En esta investigación se implementó un sistema de inferencia neurodifusa adaptativa (ANFIS) para modelar la temperatura media y la precipitación mensual a partir de registros climáticos correspondientes al período 2017–2025. El conjunto de datos incluyó temperatura, precipitación, humedad relativa, velocidad del viento, presión atmosférica y radiación solar, complementadas con variables temporales cíclicas y retardos destinados a representar las dependencias estacionales. Los datos fueron divididos cronológicamente en conjuntos de entrenamiento, validación y prueba, reservándose el último para

una evaluación independiente. La temperatura fue modelada directamente mediante ANFIS, mientras que para la precipitación se empleó un esquema híbrido que integró ANFIS, climatología mensual y componentes de persistencia temporal. En el conjunto de prueba, la temperatura alcanzó un RMSE de 0,48°C, MAE de 0,40°C, NSE de 0,288 y Bias de 0,34°C. Para la precipitación se obtuvo un RMSE de 41,50mm, MAE de 32,51mm, NSE de 0,337 y Bias de 18,66mm. La evaluación de eventos de precipitación elevada presentó un POD de 1,00, FAR de 0,50 y CSI de 0,50. Los resultados muestran que el enfoque propuesto reproduce parcialmente la dinámica temporal de ambas variables y permite generar proyecciones para 2026–2027, aunque con mayores limitaciones asociadas a la variabilidad de la precipitación.

Introducción

El análisis y la predicción de variables climáticas han adquirido importancia estratégica en el contexto del cambio climático mundial, debido a su impacto directo en la población global, la gestión sostenible de recursos hídricos y la mitigación de riesgos asociados a eventos meteorológicos extremos. La creciente variabilidad climática observada en las últimas décadas ha intensificado la necesidad de desarrollar modelos predictivos capaces de

representar adecuadamente la dinámica atmosférica en entornos complejos (WMO, 2022). En regiones de alta complejidad topográfica, como los valles de Quito, estas tareas resultan particularmente desafiantes debido a la interacción de factores topográficos, atmosféricos y oceánicos, que generan comportamientos no lineales difíciles de modelar mediante enfoques convencionales.

Variables climáticas fundamentales, como la temperatura, la precipitación y diversos índices asociados, presentan dinámicas complejas caracterizadas por fluctuaciones espaciales y temporales

influenciadas tanto por fenómenos locales como globales. Estas características pueden limitar la capacidad de los modelos estadísticos tradicionales para describir la evolución del sistema climático, especialmente bajo supuestos de linealidad y estacionariedad (Wilks, 2011). En este contexto, la modelación climática requiere metodologías capaces de representar relaciones no lineales, incertidumbre y patrones dinámicos complejos.

Las técnicas basadas en inteligencia artificial han emergido como herramientas para la predicción meteorológica y climática. Entre ellas se encuentran

PALABRAS CLAVE / Cambio Climático / Lógica Difusa / Modelo ANFIS / Modelos Climáticos / Redes Neuronales /

Recibido: 05/05/2026. Modificado: 11/09/2026. Aceptado: 14/09/2026.

Leonardo David Ruiz Aguirre (Autor de correspondencia). Ingeniero en Electrónica y Telecomunicaciones, Escuela Politécnica Nacional. Estudiante de Maestría en Matemática Aplicada con mención en Matemática Computacional, Universidad Nacional de Chimborazo, Ecuador. Dirección: Calle Leonardo Murialdo y Gaspar Tello, Pasaje B, Lote 5 170514 Quito, Pichincha, Ecuador. e-mail: leonardo.ruiz@unach.edu.ec. ORCID: 0009-0001-8945-3190.

María Fernanda Caizatoa Chulca. Ingeniera en Electrónica Automatización y Control, Universidad de la Fuerzas Armadas-ESPE. Estudiante de Maestría en Matemática Aplicada con mención en Matemática Computacional Universidad Nacional de Chimborazo. e-mail: mfcaizatoa@espe.edu.ec. ORCID:0009-0002-4611-8082.

los sistemas neurodifusos adaptativos, particularmente el Adaptive Neuro-Fuzzy Inference System (ANFIS), capaz de representar sistemas no lineales mediante la integración de redes neuronales artificiales y lógica difusa (Jang, 1993). Este enfoque combina la capacidad de aprendizaje de las redes neuronales con la interpretabilidad de los sistemas difusos, lo que permite establecer reglas lingüísticas mientras se modelan relaciones complejas presentes en los datos climáticos.

Diversos estudios han reportado resultados favorables de la aplicación de ANFIS en la predicción de variables hidrometeorológicas y mejoras en la precisión respecto de modelos convencionales (Yaseen *et al.*, 2019). En particular, se ha evaluado su eficacia en la estimación de precipitación, caudales y otras variables con alta variabilidad temporal, así como su capacidad para representar dependencias no lineales y patrones en series temporales complejas (Nayak *et al.*, 2004; Kisi y Shiri, 2011). Asimismo, se han explorado enfoques híbridos que integran ANFIS con algoritmos de optimización, procesamiento de señales y técnicas de aprendizaje profundo, con mejoras en el desempeño predictivo y la robustez frente a datos ruidosos o incompletos.

No obstante, gran parte de los estudios se ha enfocado en la predicción individual de variables climáticas, desde una perspectiva predominantemente univariante. Aunque estos enfoques han mostrado resultados satisfactorios, presentan limitaciones para representar las interacciones dinámicas entre diferentes componentes del sistema climático, las cuales desempeñan un papel fundamental en la evolución temporal de las condiciones atmosféricas (Huntingford *et al.*, 2019). En consecuencia, la modelación independiente de variables puede conducir a una representación parcial del comportamiento climático.

Asimismo, numerosas investigaciones se han desarrollado en contextos geográficos con condiciones relativamente homogéneas y la aplicación de modelos neurodifusos continúa siendo limitada en regiones de elevada complejidad climática y topográfica. En este sentido, los valles de Quito constituyen un escenario de especial interés científico debido a la influencia de factores altitudinales, de la variabilidad atmosférica regional y de fenómenos oceánicos en la dinámica climática local (IPCC, 2021). Además, diversos trabajos no incorporan sistemáticamente procedimientos de preprocesamiento de datos, tales como normalización, tratamiento de valores faltantes y selección de variables relevantes, los cuales pueden influir en la capacidad de generalización y en la precisión de los modelos predictivos.

En este contexto, resulta necesario desarrollar enfoques multivariantes capaces de integrar diferentes parámetros climáticos en un mismo esquema predictivo, particularmente en regiones geográficas complejas (Dawson y Wilby, 2001). La consideración conjunta de variables como temperatura, precipitación, humedad relativa, velocidad del viento, presión atmosférica y radiación solar permite representar de forma más integral las interacciones presentes en el sistema atmosférico (Maier y Dandy, 2000). Sin embargo, la evidencia sobre la aplicación de estos enfoques en regiones andinas de alta complejidad topográfica continúa siendo limitada, donde la interacción entre factores geográficos, atmosféricos y estacionales genera patrones climáticos particularmente difíciles de modelar.

Por tanto, el objetivo principal de esta investigación es evaluar la capacidad del modelo ANFIS para representar y predecir la dinámica multivariante del clima en los valles de Quito mediante el análisis conjunto de variables climáticas relevantes. Asimismo, se busca contribuir al desarrollo de herramientas predictivas aplicables a la toma de decisiones en áreas relacionadas con la gestión ambiental, la planificación territorial y la mitigación de riesgos climáticos. A diferencia de numerosos estudios previos enfocados en la predicción individual de variables meteorológicas, se propone un esquema de modelación que integra variables climáticas y temporales en una arquitectura neurodifusa adaptativa, complementada con el análisis de factores geográficos de la zona de estudio. Asimismo, se incorporan componentes estacionales cíclicos y retardos temporales para representar la memoria dinámica del sistema climático y capturar patrones asociados con la estacionalidad y la evolución temporal de las variables analizadas.

Adicionalmente, se desarrolla una estrategia híbrida para la predicción de la precipitación, combinando la salida generada por el modelo ANFIS con información climatológica reciente y componentes de persistencia temporal. Esta aproximación busca mejorar la estabilidad de las proyecciones ante la elevada variabilidad y no estacionariedad de los fenómenos hidrometeorológicos andinos. En este sentido, la principal contribución de este trabajo radica en la implementación y evaluación de un enfoque predictivo multivariante e híbrido aplicado específicamente a los valles de Quito, que permite evaluar la aplicabilidad de los sistemas neurodifusos adaptativos en un entorno climático complejo y aporta una base metodológica para futuras investigaciones

sobre análisis climático regional y escenarios de variabilidad climática.

Metodología

El desarrollo metodológico de este estudio comprende una serie de etapas orientadas a la construcción y validación de un modelo predictivo basado en un sistema de inferencia neurodifusa adaptativa. Estas etapas incluyen el procesamiento y análisis de datos climáticos, la definición de variables de entrada y salida, la implementación del modelo ANFIS y la evaluación de su desempeño mediante métricas cuantitativas. De esta manera, se establece un marco sistemático para modelar la dinámica climática a partir de datos observacionales (Buytaert *et al.*, 2011).

El estudio se desarrolló a partir de registros meteorológicos correspondientes al periodo 2017–2025 para los valles de Quito. Los datos observacionales fueron obtenidos de estaciones meteorológicas oficiales administradas por el Instituto Nacional de Meteorología e Hidrología del Ecuador (INAMHI) y de registros disponibles en la base Global Historical Climatology Network Daily (GHCN-Daily) de la National Oceanic and Atmospheric Administration (NOAA). Se consideraron las estaciones Yaruquí, IASA, Cumbayá, El Tingo, La Tola (Tumbaco), Pintag-El Carmen, Paluguillo y Pifo, seleccionadas de acuerdo con su ubicación dentro del área de estudio, continuidad temporal y disponibilidad de registros. Cuando fue necesario, la información se complementó con productos climáticos de libre acceso, como CHIRPS, NASA POWER y ERA5. El conjunto de datos consolidado incluyó temperatura media $T(t)$, precipitación $P(t)$, humedad relativa $H(t)$, velocidad del viento $V(t)$, presión atmosférica $Pr(t)$ y radiación solar $R(t)$, además de variables geográficas como longitud y altitud, así como componentes temporales correspondientes al año y al mes.

Previo al modelado, se llevó a cabo un preprocesamiento destinado a garantizar la calidad de los datos, que incluyó la depuración de valores inconsistentes, la verificación de la continuidad temporal y el tratamiento de los valores faltantes mediante interpolación. Posteriormente, todas las variables fueron normalizadas mediante el método min-max, a fin de evitar efectos derivados de las diferencias de escala durante el entrenamiento del modelo (Kotsiantis *et al.*, 2006). La normalización min-max se define mediante la ecuación 1:

$$X^{\text{norm}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (1)$$

donde x representa el valor original de la variable, y $x_{\min}$, $x_{\max}$ corresponden a sus valores mínimo y máximo, respectivamente.

El modelo propuesto se basa en un sistema de inferencia neurodifusa adaptativa (ANFIS), implementado mediante un esquema de inferencia de tipo Sugeno (Takagi y Sugeno, 1985) de primer orden. Dado un conjunto de variables de entrada $x(t)=[H(t),V(t),Pr(t),R(t),M(t)]$, donde $M(t)$ representa la componente temporal (mes), las reglas difusas se definen mediante la ecuación 2:

$$\text{Si } x_1 \text{ es } A_1^1 \wedge x_2 \text{ es } A_1^2 \wedge \dots \wedge x_n \text{ es } A_1^n \\ \Rightarrow y_i = \sum_{j=1}^n p_{ij}x_j + r_i \quad (2)$$

donde A_i^j son las funciones de membresía asociadas a cada variable de entrada, y p_{ij} , r_i son los parámetros del consecuente.

La activación de cada regla se calcula mediante la ecuación 3:

$$w_i = \prod_{j=1}^n \mu_{A_i^j} x_j \quad (3)$$

La activación de las reglas se normaliza de acuerdo con la ecuación 4:

$$\bar{w}_i = \frac{w_i}{\sum_k w_k} \quad (4)$$

Finalmente, la salida del modelo se obtiene mediante una combinación ponderada de los consecuentes (ecuación 5).

$$y(t) = \sum_i \bar{w}_i y_i \quad (5)$$

Esta estrategia permite reducir la complejidad asociada a la implementación directa de sistemas multisalida en ANFIS.

En este estudio, se adoptó un enfoque multisalida mediante la implementación de modelos ANFIS independientes para cada variable objetivo. Específicamente, se construyeron dos modelos: uno para la predicción de la temperatura $T(t)$ y otro para la precipitación $P(t)$, ambos utilizando el mismo conjunto de variables de entrada (Shamshirband *et al.*, 2020).

Las funciones de membresía empleadas fueron de tipo gaussiano, definidas mediante la ecuación 6.

$$\mu(x) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (6)$$

donde c es el centro y σ la desviación estándar. número de funciones de membresía por variable fue seleccionado de manera empírica, buscando un equilibrio entre la capacidad de representación y la complejidad del modelo.

El entrenamiento del modelo se realizó mediante optimización basada en gradiente utilizando el algoritmo Adam. La función objetivo correspondió al error cuadrático medio (MSE) entre las salidas observadas y las estimadas por el modelo, durante cada época, los gradientes de los parámetros asociados tanto a las funciones de membresía gaussianas como a los consecuentes de las reglas difusas se calcularon mediante retropropagación y se actualizaron conjuntamente con Adam. Este procedimiento permite minimizar el error entre las salidas reales y las predichas (Cisternas Jiménez y Yin, 2025). La implementación computacional se realizó en Python, utilizando las bibliotecas NumPy, Pandas y Scikit-learn para el procesamiento y normalización de los datos, la partición del conjunto de datos y la evaluación del desempeño.

Debido a la naturaleza altamente variable y no estacionaria de la precipitación, caracterizada por la presencia de eventos extremos y una mayor dispersión temporal en comparación con otras variables climáticas, se implementó una estrategia híbrida para su modelación predictiva. Este enfoque combinó la salida generada por el modelo ANFIS con componentes climatológicos y de persistencia temporal, con el propósito de mejorar la estabilidad y coherencia física de las predicciones futuras. La componente climatológica se obtuvo a partir del comportamiento promedio reciente de la precipitación para cada periodo mensual, mientras que la componente de persistencia incorporó la información contenida en observaciones previas de la serie temporal. La predicción final se calculó mediante una combinación ponderada de estas tres fuentes de información, permitiendo reducir la sensibilidad del modelo frente a fluctuaciones abruptas y mejorar su capacidad de generalización (Haykin, 2009). La adopción de este enfoque se fundamenta en que los fenómenos hidrometeorológicos presentan una elevada incertidumbre y componentes estacionales que no siempre pueden ser capturadas de manera adecuada por un único modelo de aprendizaje, por lo que la integración de información climatológica auxiliar contribuye a generar estimaciones más robustas y firmemente consistentes.

Para la evaluación del desempeño, el conjunto de datos fue dividido siguiendo un criterio estrictamente temporal, sin aleatorización. Debido a la incorporación de retardos de hasta 12 meses, la serie efectiva para el modelado comprendió 96 observaciones mensuales entre enero de 2018 y diciembre de 2025. Se destinaron 67 observaciones (69,79%) al entrenamiento, correspondientes a enero de 2018-julio de 2023; 14

observaciones (14,58%) a la validación, entre agosto de 2023 y septiembre de 2024; y 15 observaciones (15,62%) a la prueba independiente, entre octubre de 2024 y diciembre de 2025. Esta distribución se aplicó de forma uniforme a todas las variables climáticas consideradas. El conjunto de validación se empleó para controlar el entrenamiento y ajustar el modelo híbrido de precipitación, mientras que el conjunto de prueba se reservó exclusivamente para la evaluación final.

El desempeño del modelo se cuantificó mediante métricas estándar de regresión, incluyendo el error cuadrático medio (RMSE), el error absoluto medio (MAE), la eficiencia de Nash-Sutcliffe (NSE) y el sesgo medio (Bias). El RMSE (ecuación 7) y el MAE (ecuación 8) permitieron cuantificar la magnitud del error entre los valores observados y predichos, mientras que el NSE (ecuación 9) evaluó la capacidad del modelo para reproducir la variabilidad temporal de las observaciones. El Bias (ecuación 10) se utilizó para identificar tendencias sistemáticas de sobreestimación o subestimación (Willmott y Matsuura, 2005).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (7)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \bar{y}_i| \quad (8)$$

$$NSE = 1 - \frac{\left(\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y}_i)^2 \right)}{\left(\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2 \right)} \quad (9)$$

$$Bias = \frac{1}{N} \sum_{i=1}^N (\bar{y}_i - y_i) \quad (10)$$

donde y_i representa los valores observados, $(\bar{y}_i)$ los valores predichos por el modelo y N el número total de observaciones.

Finalmente, los resultados fueron analizados mediante la comparación entre las series temporales observadas y predichas, con el propósito de evaluar la capacidad del modelo para representar la dinámica temporal de las variables climáticas en un entorno caracterizado por alta variabilidad.

La Figura 1 muestra el diagrama de flujo correspondiente a la implementación del modelo ANFIS propuesto para la predicción de variables climáticas. El proceso inicia con la preparación del conjunto de datos, que comprende la limpieza, validación y normalización de las variables, seguida de la selección de las variables de entrada y salida del modelo.

Resultados y Discusión

En esta sección se presentan los resultados obtenidos del análisis




Figura 1. Diagrama de flujo del modelo ANFIS implementado.

de los datos climáticos correspondientes al periodo 2017–2025, orientado a identificar

patrones temporales, dependencias entre variables y características estructurales

relevantes para el modelado predictivo. Mediante la caracterización estadística y el

análisis gráfico, se examinan la dinámica temporal de las principales variables y las relaciones existentes entre ellas.

El análisis permite caracterizar la variabilidad temporal y espacial del sistema climático estudiado y explorar las relaciones entre las variables consideradas. En particular, se examinan la evolución temporal de la temperatura y la precipitación, las correlaciones entre variables meteorológicas y geográficas y las relaciones bivariadas de mayor relevancia para el modelado.

Los resultados obtenidos proporcionan la base para la selección de las variables de entrada y la implementación posterior del modelo ANFIS para la predicción de la temperatura y la precipitación.

Análisis exploratorio

Con el fin de caracterizar la estructura del conjunto de datos y examinar las relaciones entre las variables climáticas consideradas, se realizó un análisis exploratorio basado en su evolución temporal y en la correlación estadística. Debido a que los registros procedieron de diferentes fuentes, previamente se efectuó la homogeneización de las unidades de medida, a fin de garantizar la uniformidad y comparabilidad de las variables utilizadas en el análisis.

La Figura 2 presenta la evolución temporal de la precipitación media mensual y la temperatura media mensual durante el periodo 2017–2025. Ambas variables muestran comportamientos diferenciados. La temperatura presenta una variabilidad relativamente moderada, con valores comprendidos aproximadamente entre 13,0 y 16,6°C. Aunque

existen fluctuaciones interanuales, la serie mantiene una evolución comparativamente continua durante el periodo analizado.

En contraste, la precipitación exhibe una mayor variabilidad temporal, con una alternancia de meses de baja precipitación y periodos con incrementos pronunciados. Se observan máximos mensuales cercanos a 340mm y varios intervalos con valores reducidos, lo que evidencia una mayor dispersión respecto de la temperatura. Esta variabilidad constituye un desafío adicional para la predicción de la precipitación y respalda la incorporación de información temporal y climatológica en el modelado.

La comparación de ambas series no evidencia una relación temporal directa y persistente entre la temperatura y la precipitación. Si bien en determinados periodos pueden observarse variaciones simultáneas, este comportamiento no se mantiene de manera uniforme a lo largo de la serie, lo que indica que la relación entre ambas variables no presenta un patrón temporal simple y persistente.

La Figura 3 presenta la matriz de correlación de Pearson entre las variables climáticas, geográficas y temporales consideradas. La asociación lineal de mayor magnitud se observa entre la velocidad del viento y la presión atmosférica ($r=0,98$), lo que indica una fuerte asociación estadística entre ambas variables dentro del conjunto de datos. Asimismo, se identifica una correlación negativa elevada entre la humedad relativa y la radiación solar ($r=-0,79$).

La temperatura presenta correlaciones moderadas con la radiación solar ($r=0,51$), la humedad relativa

($r=-0,50$) y la altitud ($r=-0,44$). Estas asociaciones indican relaciones lineales de distinta magnitud entre la temperatura y las variables consideradas. También se observa una correlación positiva entre altitud y longitud ($r=0,56$), relacionada con la distribución espacial de los puntos de observación.

Por su parte, la precipitación presenta correlaciones lineales predominantemente débiles con las demás variables. La asociación de mayor magnitud corresponde a la humedad relativa ($r=0,31$), seguida por la radiación solar ($r=-0,19$). Las correlaciones con temperatura ($r=-0,10$), velocidad del viento ($r=0,10$), presión atmosférica ($r=0,11$), altitud ($r=0,04$), longitud ($r=-0,09$) y mes ($r=-0,07$) son reducidas. Estos resultados indican que, dentro del conjunto de datos analizado, no se identifica una asociación lineal dominante entre la precipitación y una única variable.

Finalmente, la variable mes presenta asociaciones de $r=-0,43$ con la humedad relativa y $r=0,33$ con la radiación solar, compatibles con la presencia de un componente estacional en el comportamiento de estas variables. En conjunto, la coexistencia de correlaciones de distinta magnitud y signo, junto con la variabilidad temporal observada, evidencia la complejidad de las relaciones entre las variables analizadas y respalda la aplicación de un enfoque capaz de representar relaciones no lineales, como ANFIS, en la etapa predictiva.

Implementación del modelo ANFIS

Con el objetivo de modelar la evolución temporal de las




Figura 2. Evolución temporal de precipitación y temperatura para los Valles de Quito de 2017 a 2025.




Figura 3. Matriz de correlación de variables climáticas en los Valles de Quito de 2017 a 2025.

principales variables climáticas de los valles de Quito, se implementó un sistema de inferencia neurodifusa adaptativa (ANFIS, Adaptive Neuro-Fuzzy Inference System) en Python. El modelo utilizó información climática mensual del período 2017–2025, previamente depurada y con unidades homogeneizadas, e incorporó temperatura media, precipitación, humedad relativa, velocidad del viento, presión atmosférica y radiación solar. Además, se incluyeron componentes temporales cíclicos mediante funciones seno y coseno del mes y retardos de 1, 2, 3 y 12 meses, destinados a representar dependencias temporales de corto plazo y estacionales.

La arquitectura empleada correspondió a un sistema de inferencia de tipo Sugeno de primer orden con funciones de pertenencia gaussianas. Para cada variable objetivo se implementó un modelo ANFIS independiente con cuatro reglas difusas. Los parámetros de las

funciones de pertenencia y de los consecuentes fueron optimizados conjuntamente mediante el algoritmo Adam, utilizando como función objetivo el error cuadrático medio (MSE). Para mejorar la estabilidad del entrenamiento se aplicaron normalización min–max, regularización y detención temprana. La temperatura se modeló directamente mediante ANFIS, mientras que para la precipitación se utilizó un esquema híbrido que combinó la salida del modelo ANFIS con climatología mensual, persistencia del mes anterior y la precipitación registrada en el mismo mes del año precedente.

Debido al uso de retardos de hasta 12 meses, la serie efectiva quedó constituida por 96 observaciones mensuales entre enero de 2018 y diciembre de 2025. Se utilizaron 67 observaciones (69,79%) para entrenamiento, 14 (14,58%) para validación y 15 (15,62%) para prueba independiente. La partición se

realizó de forma cronológica, sin aleatorización. El conjunto de validación se empleó para controlar el entrenamiento y seleccionar los pesos del modelo híbrido de precipitación, mientras que el conjunto de prueba se reservó exclusivamente para la evaluación final.

Las Figuras 4 y 5 muestran los resultados obtenidos para la precipitación y la temperatura media mensual, respectivamente. En ambos casos se presentan la serie histórica, las estimaciones correspondientes al conjunto independiente de prueba y las proyecciones generadas para 2026–2027.

Para la precipitación (Figura 4), el modelo híbrido alcanzó un RMSE de 41,50mm, un MAE de 32,51mm y un NSE de 0,337. El Bias de 18,66mm indica una tendencia a la sobreestimación durante el período de prueba. Aunque el valor de NSE indica que el modelo reproduce parcialmente la




Figura 4. Gráfica de la evolución temporal de precipitación y predicción a 2027 del modelo ANFIS y datos externos.




Figura 5. Gráfica de la evolución temporal de temperatura y predicción a 2027 del modelo ANFIS y datos externos.

variabilidad observada, los resultados confirman la mayor dificultad asociada a la predicción de la precipitación, caracterizada por fluctuaciones temporales pronunciadas y la ocurrencia irregular de valores de mayor magnitud.

La evaluación específica de estos episodios mostró un POD de 1,00, un FAR de 0,50 y un CSI de 0,50, considerando como evento una precipitación mensual igual o superior al percentil 75 del conjunto de entrenamiento. El POD indica que los eventos observados fueron detectados; sin embargo, el FAR evidencia la presencia de falsas alarmas, en concordancia con la tendencia general a la sobreestimación indicada por el Bias positivo. En este contexto, el esquema híbrido permitió

mantener una evolución temporal estable de las predicciones, aunque persiste una tendencia a sobreestimar determinados períodos de precipitación.

Estos resultados son consistentes con lo señalado por Nayak *et al.* (2004) y Kisi y Shiri (2011), quienes reportaron la capacidad de los modelos neurodifusos para representar relaciones no lineales en series hidrometeorológicas, así como las dificultades asociadas al modelado de variables con elevada variabilidad temporal y fluctuaciones pronunciadas.

Para la temperatura media mensual (Figura 5), el modelo ANFIS obtuvo un RMSE de 0,48°C, un MAE de 0,40°C, un NSE de 0,288 y un Bias de 0,34°C. Los errores absolutos indican

proximidad entre los valores observados y predichos; sin embargo, el valor de NSE evidencia una capacidad limitada para reproducir la variabilidad temporal observada. El Bias positivo refleja una ligera tendencia a sobreestimar la temperatura durante el período de prueba.

La temperatura mostró una mayor continuidad temporal que la precipitación, con una reproducción más estable de su comportamiento general y de sus oscilaciones estacionales. Este resultado es consistente con lo señalado por Maier y Dandy (2000) y con estudios posteriores que destacan la utilidad de incorporar información temporal y procedimientos adecuados de preprocesamiento en modelos de inteligencia artificial aplicados a variables meteorológicas.

Las proyecciones para 2026–2027 presentaron patrones estacionales compatibles con el comportamiento histórico reciente. Las estimaciones procedentes de fuentes meteorológicas externas se incluyeron únicamente como referencia comparativa y no como mecanismo de validación independiente, debido a que las metodologías utilizadas por estas plataformas no están completamente documentadas para el usuario final.

La Tabla I resume los indicadores obtenidos para el conjunto independiente de prueba. En conjunto, los resultados muestran que el desempeño del modelo depende de la naturaleza de la variable analizada. La temperatura presentó menores errores absolutos y una evolución temporal más regular, mientras que la precipitación mostró mayor incertidumbre y una tendencia más marcada a la sobreestimación. La incorporación de componentes climatológicos y de persistencia complementó la salida del modelo ANFIS en la predicción de la precipitación, mientras que la partición temporal y la utilización de un conjunto independiente de prueba permitieron evaluar su capacidad de generalización.

Conclusiones

La implementación del modelo neurodifuso ANFIS permitió representar la dinámica temporal de la temperatura y la precipitación en los valles de Quito a partir de información meteorológica multivariable y componentes temporales. El análisis exploratorio evidenció comportamientos diferenciados entre ambas variables, con una mayor continuidad temporal de la temperatura y una variabilidad más pronunciada de la precipitación, así como asociaciones lineales de distinta magnitud entre las variables climáticas y geográficas consideradas.

La evaluación mediante una partición temporal independiente mostró que el desempeño del modelo dependió de la naturaleza de la variable analizada. Para la temperatura se obtuvo un RMSE de 0,48°C, un MAE de 0,40°C, un NSE de 0,288 y un Bias de 0,34°C, lo que indica errores absolutos reducidos, una capacidad limitada para reproducir la variabilidad temporal observada y una ligera tendencia a la sobreestimación. Para la precipitación, el esquema híbrido alcanzó un RMSE de 41,50mm, un MAE de

32,51mm, un NSE de 0,337 y un Bias de 18,66mm, lo que evidencia una capacidad parcial para reproducir la variabilidad observada y una mayor incertidumbre asociada a su comportamiento temporal.

La evaluación complementaria de la precipitación mediante POD, FAR y CSI permitió analizar la detección de los eventos de mayor magnitud. El POD de 1,00 indicó que los eventos observados en el conjunto de prueba fueron detectados, mientras que el FAR de 0,50 y el CSI de 0,50 mostraron la presencia de falsas alarmas y las limitaciones que persisten en la representación de esta variable. En este contexto, la incorporación de climatología mensual y componentes de persistencia complementó la salida del modelo ANFIS y contribuyó a estabilizar las predicciones obtenidas.

Las proyecciones para 2026–2027 mostraron patrones compatibles con el comportamiento climático reciente; sin embargo, constituyen proyecciones no validadas, ya que las observaciones reales correspondientes a dicho período aún no están disponibles. Por esta razón, las estimaciones provenientes de plataformas meteorológicas externas se utilizaron únicamente como referencia comparativa y no como criterio de validación del modelo.

Una limitación relevante del estudio corresponde a la extensión de la serie temporal disponible, comprendida entre 2017 y 2025. Aunque este período permitió desarrollar y evaluar el enfoque propuesto, resulta menor que el horizonte de aproximadamente 30 años recomendado para una caracterización climatológica de largo plazo. En consecuencia, los resultados representan principalmente la dinámica climática reciente de la zona de estudio y las proyecciones deben interpretarse dentro de este alcance temporal.

Como línea futura de investigación, se recomienda ampliar la serie histórica, incorporar variables atmosféricas y oceánicas de mayor escala y evaluar arquitecturas híbridas y modelos temporales avanzados. Estas extensiones podrían contribuir a mejorar la capacidad de generalización y reducir la incertidumbre, particularmente en la predicción de la precipitación.

REFERENCIAS

Buytaert W, Cuesta-Camacho F, Tobón C (2011) Potential impacts of climate change on the

environmental services of humid tropical alpine regions. *Glob. Ecol. Biogeogr.* 20: 19–33.

Chen Y, Li B, Singh VP (2020) Adaptive neuro-fuzzy inference system modeling for hydrological time series: A review of applications and challenges. *Environ. Modell. Softw.* 124: 104607.

Cisternas Jiménez E, Yin FF (2025) Adaptive Neuro-Fuzzy Inference System guided objective function parameter optimization for inverse treatment planning. *Front. Artif. Intell.* 8: 1523390.

Dawson CW, Wilby RL (2001) Hydrological modelling using artificial neural networks. *Prog. Phys. Geogr.* 25: 80–108.

Haykin S (2009) *Neural Networks and Learning Machines*. 3rd ed. Prentice Hall. Upper Saddle River, NJ, EE.UU. 936 pp.

Huntingford C, Jeffers ES, Bonsall MB, Christensen HM, Lees T, Yang H (2019) Machine learning and artificial intelligence to aid climate change research and preparedness. *Environ. Res. Lett.* 14: 124007.

IPCC (2021) *Climate Change 2021: The Physical Science Basis*. Cambridge University Press. Cambridge, RU. 2391 pp.

Jang JSR (1993) ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Trans. Syst. Man Cybern.* 23: 665–685.

Kisi O, Shiri J (2011) Precipitation forecasting using wavelet-genetic programming and wavelet-neuro-fuzzy conjunction models. *Water Resour. Manag.* 25: 3135–3152.

Kotsiantis SB, Kanellopoulos D (2006) Data preprocessing for supervised learning. *Int. J. Comput. Sci.* 1: 111–117.

Maier HR, Dandy GC (2000) Neural networks for the prediction and forecasting of water resources variables: A review. *Environ. Modell. Softw.* 15: 101–124.

Nayak PC, Sudheer KP, Rangan DM, Ramasastri KS (2004) A neuro-fuzzy computing technique for modeling hydrological time series. *J. Hydrol.* 291: 52–66.

Shamshirband S, Mosavi A, Rabczuk T, Nabipour N, Chau KW (2020) Prediction of significant wave height; comparison between nested grid numerical model, and machine learning models of artificial neural networks, extreme learning and support vector machines. *Eng. Appl. Comput. Fluid Mech.* 14: 805–817.

Takagi T, Sugeno M (1985) Fuzzy identification of systems and its applications to modeling and control. *IEEE Trans. Syst. Man Cybern.* SMC-15: 116–132.

Wilks DS (2011) *Statistical Methods in the Atmospheric Sciences*. 3rd ed. Academic Press. Burlington, MA, EE.UU. 676 pp.

Willmott CJ, Matsuura K (2005) Advantages of the mean absolute error (MAE) over RMSE. *Clim. Res.* 30: 79–82.

World Meteorological Organization (2022) *State of the Global Climate 2021*. WMO - No. 1290. Ginebra, Suiza. 55 pp.

Yaseen ZM, Sulaiman SO, Deo RC, Chau KW (2019) An enhanced extreme learning machine model for river flow forecasting: State-of-the-art, practical applications in water resource engineering area and future research direction. *J. Hydrol.* 569: 387–408.

Yaseen ZM et al. (2019) Streamflow forecasting using artificial intelligence models: A review of methods and applications. *J. Hydrol.* 575: 336–36.

TABLA I
RESUMEN DE ÍNDICES DE DESEMPEÑO DEL MODELO ANFIS PARA
PRECIPITACIÓN Y TEMPERATURA

Variable	RMSE	MAE	NSE	BIAS
Precipitación	41,50mm	32,51mm	0,337	18,66mm
Temperatura	0,48°C	0,40°C	0,288	0,34°C

ANFIS MODEL FOR CLIMATE PREDICTION IN THE VALLEYS OF QUITO, ECUADOR

Leonardo David Ruiz Aguirre and María Fernanda Caizatoa Chulca

SUMMARY

Climate variable prediction poses a challenge due to the non-linear and variable nature of atmospheric systems, particularly in Andean regions such as the valleys of Quito, Ecuador. In this study, an adaptive neuro-fuzzy inference system (ANFIS) was implemented to model mean temperature and monthly precipitation using climate records for the 2017–2025 period. The dataset included temperature, precipitation, relative humidity, wind speed, atmospheric pressure, and solar radiation, complemented by cyclical temporal variables and lags intended to represent seasonal dependencies. The data were chronologically divided into training, validation, and testing sets, with the latter reserved for independent evaluation. Temperature was modeled

directly using ANFIS, whereas precipitation was modeled using a hybrid scheme integrating ANFIS, monthly climatology, and temporal persistence components. In the test set, temperature yielded an RMSE of 0.48°C, MAE of 0.40°C, NSE of 0.288, and Bias of 0.34°C. For precipitation, an RMSE of 41.50mm, MAE of 32.51mm, NSE of 0.337, and Bias of 18.66mm were obtained. Evaluation of high-precipitation events yielded a POD of 1.00, FAR of 0.50, and CSI of 0.50. The results show that the proposed approach partially reproduces the temporal dynamics of both variables and allows projections to be generated for 2026–2027, although with greater limitations associated with precipitation variability.

MODELO ANFIS PARA PREDIÇÃO DO CLIMA NOS VALES DE QUITO, EQUADOR

Leonardo David Ruiz Aguirre e Maria Fernanda Caizatoa Chulca

RESUMO

A predição de variáveis climáticas constitui um desafio devido à natureza não linear e variável dos sistemas atmosféricos, particularmente em regiões andinas como os vales de Quito, Equador. Nesta pesquisa, foi implementado um sistema de inferência neurodifusa adaptativa (ANFIS) para modelar a temperatura média e a precipitação mensal a partir de registros climáticos correspondentes ao período 2017–2025. O conjunto de dados incluiu temperatura, precipitação, umidade relativa, velocidade do vento, pressão atmosférica e radiação solar, complementadas por variáveis temporais cíclicas e defasagens destinadas a representar as dependências sazonais. Os dados foram divididos cronologicamente em conjuntos de treinamento, validação e teste, reservando-se o último para uma avaliação

independente. A temperatura foi modelada diretamente por meio do ANFIS, enquanto, para a precipitação, foi empregado um esquema híbrido que integrou ANFIS, climatologia mensal e componentes de persistência temporal. No conjunto de teste, a temperatura apresentou RMSE de 0,48°C, MAE de 0,40°C, NSE de 0,288 e Bias de 0,34°C. Para a precipitação, foram obtidos RMSE de 41,50mm, MAE de 32,51mm, NSE de 0,337 e Bias de 18,66mm. A avaliação de eventos de precipitação elevada apresentou POD de 1,00, FAR de 0,50 e CSI de 0,50. Os resultados mostram que a abordagem proposta reproduz parcialmente a dinâmica temporal de ambas as variáveis e permite gerar projeções para 2026–2027, embora com maiores limitações associadas à variabilidade da precipitação

Licencia de uso



Esta obra está bajo una licencia internacional [Creative Commons Atribución-NoComercial-SinDerivadas 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/).