

MODELACIÓN UNIVARIANTE PROPHET PARA EL PRONÓSTICO DE PRECIPITACIONES EN ESTACIONES METEOROLÓGICAS DE TUNGURAHUA-ECUADOR

UNIVARIATE PROPHET MODELLING FOR PRECIPITATION FORECASTING AT METEOROLOGICAL STATIONS IN TUNGURAHUA-ECUADOR

Anthony Zabala^{1*}

¹ Facultad de Ingeniería Civil y Mecánica. Universidad Técnica de Ambato. Ecuador. ORCID: <https://orcid.org/0009-0004-6614-4186>. Correo: ar.zabala@uta.edu.ec

Luis Contreras-Vásquez²

² Dirección de Investigación y Desarrollo, Facultad de Ingeniería Civil y Mecánica. Universidad Técnica de Ambato. Ecuador. ORCID: <https://orcid.org/0000-0002-8896-8264>. Correo: lf.contreras@uta.edu.ec

Ruth Lorena Pérez Maldonado³

³ Facultad de Ingeniería Civil y Mecánica. Universidad Técnica de Ambato. Ecuador. ORCID: <https://orcid.org/0009-0003-2317-3529>. Correo: rlperez@uta.edu.ec

Mayra Viscaíno-Cuzco^{4*}

⁴ Facultad de Ingeniería Civil y Mecánica. Universidad Técnica de Ambato. Ecuador. ORCID: <https://orcid.org/0000-0003-4987-7797>. Correo: ma.viscaino@uta.edu.ec

* Autor para correspondencia: ma.viscaino@uta.edu.ec

Resumen

El pronóstico de precipitaciones es una herramienta esencial para la gestión sostenible de los recursos hídricos. Este estudio aplica el modelo univariante Prophet para estimar precipitaciones diarias en 19 estaciones meteorológicas de la provincial de Tungurahua, Ecuador, a fin de generar información confiable que respalde la toma de decisiones en los sectores de infraestructura, agricultura y gestión ambiental. Se utilizaron series de tiempo diarias de precipitación para el entrenamiento y la validación del modelo, abarcando datos registrados entre 2013 y 2024. El modelo fue evaluado bajo tres segmentaciones de datos: 80-20%, 85-15%

y 90-10% para entrenamiento y prueba, respectivamente. Además, se consideraron tanto los valores predeterminados de Prophet como la configuración de hiperparámetros encontrados mediante búsqueda por cuadrícula. El desempeño se evaluó mediante las métricas MAE y RMSE, cuyos valores oscilaron entre 1.0398 y 3.8012 mm y entre 1.8956 y 6.3168 mm, respectivamente, lo que evidencia una capacidad predictiva adecuada en relación con el promedio de la precipitación diaria. A partir de los resultados obtenidos, se determinó que el modelo Prophet mejora su precisión al incrementarse el porcentaje de datos destinados al entrenamiento, alcanzando sus mejores desempeños con las divisiones 85-15% y 90-10% para entrenamiento y validación, respectivamente, utilizando la configuración de hiperparámetros determinada mediante búsqueda por cuadrícula.

Palabras clave: Prophet; precipitaciones; pronóstico; áreas andinas

Abstract

Precipitation forecasting constitutes an essential tool for the sustainable management of water resources. This study applies the univariate Prophet model to estimate daily precipitation across 19 meteorological stations in Tungurahua Province, Ecuador, with the aim of generating reliable information to support decision-making in the infrastructure, agriculture, and environmental management sectors. Daily precipitation time series were used for model training and validation, covering data recorded between 2013 and 2024. The model was evaluated under three data partitioning schemes: 80–20%, 85–15%, and 90–10% for training and testing, respectively. In addition, both the default Prophet parameters and hyperparameter configurations obtained through grid search were considered. Model performance was assessed using the MAE and RMSE metrics, with values ranging from 1.0398 to 3.8012 mm and from 1.8956 to 6.3168 mm, respectively, indicating an adequate predictive capability relative to the average daily precipitation. Based on the results obtained, it was determined that the Prophet model improves its accuracy as the proportion of training data increases, achieving its best performance with the 85–15% and 90–10% training–validation splits when using hyperparameter configurations identified through grid search.

Keywords: Prophet; precipitation; forecast; Andean zone

Fecha de recibido: 22/01/2026

Fecha de aceptado: 23/04/2026

Fecha de publicado: 01/05/2026

Introducción

La precipitación es un evento importante dentro del ciclo hidrológico (Salih et al., 2020; Xu et al., 2020; Li et al., 2022) por su influencia sobre el ambiente y los medios de vida de una población como: la agricultura, el agua potable, el sector energético (Saha et al., 2020), etc. En cuanto a las construcciones un clima cambiante

altera las condiciones bajo las cuales los sistemas de infraestructura deben diseñarse y operar (Buhl & Markolf, 2023).

Según (Chen et al., 2025), (Yaseen et al., 2021), (Ashok & Pekkat, 2022) los eventos extremos como sequías e inundaciones están ocurriendo con mayor frecuencia en muchos lugares en el mundo. Un resumen de desastres que sucedieron en el mundo en el año 2024, indica que, del total de eventos registrados en ese año, el 36% corresponden a inundaciones. Las sequías y las inundaciones están en los eventos que más afectados y pérdidas económicas provocaron en ese año (CRED, 2025a). Mientras que, en América del Sur, entre 2000 y 2023, el EM-DAT (Emergency Events Database) registró 505 desastres hidrológicos, que en última instancia cobraron 10.694 víctimas mortales (CRED, 2025b).

Por otra parte, la precipitación tiene un comportamiento variable tanto en el espacio como en el tiempo (Salih et al., 2020), (Xu et al., 2020), (Abdaki et al., 2023). En la zona andina central del Ecuador la precipitación desempeña un rol de vital importancia debido a que es un área altamente agrícola (Saenz-Lituma, 2025), por lo que en épocas de sequía la seguridad alimentaria está en riesgo. Según (CENACE, 2025), en el año 2024 el 82% de la producción de energía en Ecuador provino de centrales hidro-eléctricas, por lo que los efectos de las bajas precipitaciones y las graves consecuencias por falta de energía fueron evidentes para la población ecuatoriana en los años 2023 y 2024 (Rodríguez-Gallegos et al., 2025).

Todo esto hace que predecir el comportamiento de las precipitaciones sea importante, particularmente para países en vías de desarrollo que buscan mitigar los impactos del clima extremo mediante la prevención (Saha et al., 2020), (Ebtehaj et al., 2020). Sin embargo, la predicción de precipitaciones es un reto para los investigadores, por-que la precipitación depende muchos factores meteorológicos (Khaniani et al., 2021), además por el comportamiento aleatorio que esta tiene (Ebtehaj et al., 2020).

Alrededor del mundo se han probado muchos modelos para pronosticar la lluvia, cada modelo tiene fortalezas y debilidades, y su desempeño varía dependiendo de los contextos temporales y espaciales (Sheikh & Coulibaly, 2024). Históricamente, el pronóstico de precipitaciones se ha abordado mediante dos técnicas de modelación de lluvia, entre los cuales están los modelos de “numerical weather prediction”, que requieren un modelo de alta resolución para la representación detallada y la comprensión de las condiciones atmosféricas. En este caso, la evolución del clima es pronosticado mediante simulación numérica de las condiciones atmosféricas (Ashok & Pekkat, 2022); y los modelos que explorando datos históricos disponibles capturan patrones espaciotemporales de la lluvia (Salih et al., 2020).

Dentro de la última categoría, se han probado algoritmos de “Machine Learning” como: los Bosques Aleatorios (RF), las Máquinas de Vectores de Soporte (SVM) y las Redes Neuronales Artificiales (RNA) (Li et al., 2022), (Katumo et al., 2025) y de “Deep Learning” como Long Short Term Memory (LSTM) (Rogers et al., 2024), (Pérez-Alarcón et al., 2022); pero estos modelos presentan problemas de interpretabilidad y dependencia de los recursos (Katumo et al., 2025).

Mientras que los modelos estadísticos más usados son los modelos autorregresivos integrados de media móvil (ARIMA) (Saha et al., 2020), (Duan et al., 2022), (Lana et al., 2021), (Dahiya et al., 2024). De acuerdo con (Saha et al., 2020), este modelo no es adecuado, si los datos de la serie temporal bajo estudio no son puramente lineales y existen relaciones espaciales.

En este contexto, el modelo estadístico denominado Prophet, creado por Taylor y Letham (Taylor & Letham, 2018), diseñado para pronóstico de series temporales, ha emergido como una herramienta flexible (Abdaki et al., 2023). A diferencia de ARIMA, el modelo Prophet se basa en un enfoque aditivo que descompone la serie en componentes de tendencia, estacionalidad y efectos irregulares, permitiendo incorporar de forma explícita estacionalidades múltiples y manejar valores atípicos de manera robusta (Katumo et al., 2025). Estas características lo han convertido en una alternativa para aplicaciones hidrológicas y meteorológicas recientes.

Aunque diversos estudios han reportado resultados favorables del modelo Prophet en el pronóstico de precipitaciones la mayoría de estas investigaciones se concentran en diferentes regiones del mundo (Hossain et al., 2022), (Bosson-Amedenu et al., 2025), (Hossain et al., 2025), (Ning et al., 2022). En el caso del Ecuador, y en particular de la zona central andina, existen escasos estudios que evalúen de manera sistemática el desempeño del modelo Prophet aplicado a series pluviométricas locales, considerando su estacionalidad compleja y alta variabilidad interanual. Esta falta de evidencia limita la adopción informada de este modelo en aplicaciones de ingeniería y gestión hídrica en la región.

El propósito de este estudio es evaluar el desempeño del modelo univariante Prophet en el pronóstico de series temporales de precipitación diaria, empleando datos históricos de las estaciones de la provincia de Tungurahua, ubicada en la región andina central del Ecuador. Se emplearán diferentes técnicas para la configuración de hiperparámetros y diferentes proporciones de datos para el entrenamiento y testeo del modelo.

La principal contribución de este trabajo es la evaluación cuantitativa de la capacidad del modelo para capturar patrones estacionales y tendencias en un contexto climático andino, evaluada mediante métricas estadísticas.

Materiales y métodos

El presente estudio se desarrolló mediante un enfoque cuantitativo y se estructuró como se presenta en Figura 1.

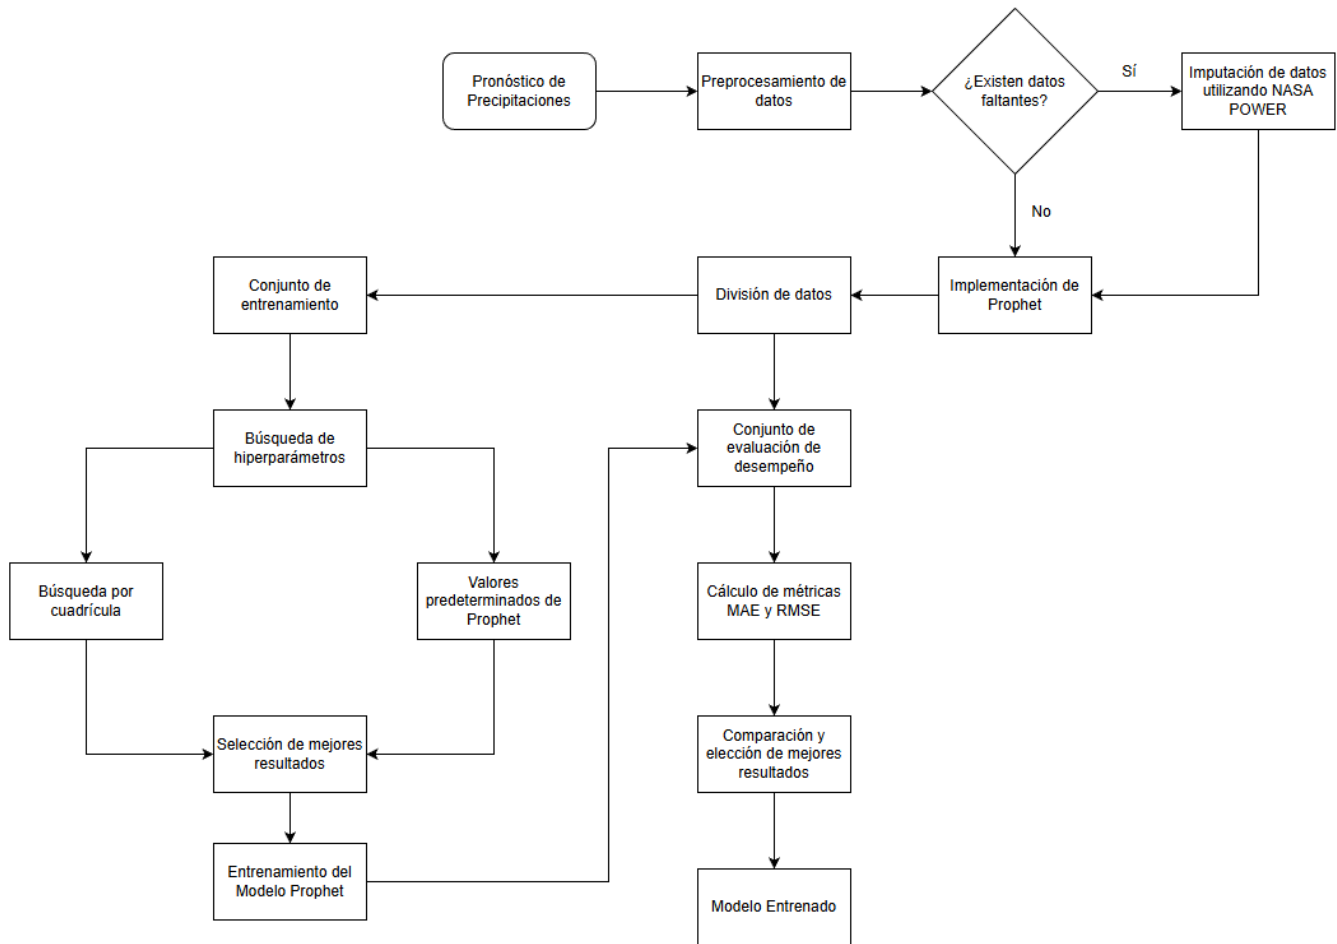


Figura 1. Diagrama de flujo de la metodología utilizada para la implementación del pronóstico de precipitaciones utilizando el modelo Prophet.

Recopilación de datos

Los registros diarios de precipitación utilizados en este estudio provienen de 19 estaciones meteorológicas ubicadas en la provincial de Tungurahua, Ecuador, administradas por el Honorable Gobierno Provincial de Tungurahua. Los periodos de registro abarcan diferentes intervalos entre 2013 y 2024, dependiendo de la disponibilidad de cada estación, la decisión de trabajar con registros diarios está fundamentada en (Abdaki et al., 2023; Rogers et al., 2024; Li et al., 2023; Ridwan et al., 2021; Unnikrishnan & Jothiprakash, 2020; Suárez-Aguilar et al., 2020; Kwarteng & Andreevich, 2024). La **¡Error! No se encuentra el origen de la referencia.** resume el número de observaciones, coordenadas UTM y elevación de cada estación.

Tabla 1. Resumen de Estaciones.

Estación	Cantón	# de Datos	Periodo de Registro		Coordenadas		Elevación (m.s.n.m)
			Inicio	Final	X	Y	
Chiquiurcu (1)	Ambato	4164	16/2/2013	11/7/2024	743787	9866064	3875
Mula Corral (2)	Ambato	4139	13/3/2013	11/7/2024	741602	9867738	3875
Quisapincha (3)	Ambato	3920	16/2/2013	10/11/2023	753559	9865921	3670
Pilahuin (4)	Ambato	3954	19/1/2013	16/11/2023	752358	9856011	3314
Aeropuerto (5)	Ambato	3734	8/2/2023	30/4/2023	769929	9865679	2590
Calamaca (6)	Ambato	3754	2/3/2013	11/6/2023	742705	9858860	3437
Tamboloma (7)	Ambato	1459	14/7/2020	11/7/2023	747919	9855365	3610
Hacienda Cunchibamba (8)	Ambato	3733	28/8/2013	16/11/2023	767300	9874583	2861
Hacienda Guadalupe (9)	Patate	3801	25/01/2013	22/06/2023	778853	9849321	2013
U. E. Benjamín Araujo (10)	Patate	3798	23/02/2013	18/07/2023	778205	9856142	2270
U. E. Antonio José de Sucre (11)	Patate	3708	14/03/2013	08/05/2023	778876	9860556	2700
Embalse Pisayambo (12)	Pillaro	3934	08/02/2013	16/11/2023	790071	9881472	3604
U. E. Jorge Álvarez (13)	Pillaro	3780	05/03/2013	10/07/2023	772342	9870622	2770
Escuela Tasinteo (14)	Pillaro	3678	20/03/2013	14/04/2023	777991	9870930	3300
Parque de la Familia (15)	Baños	4114	15/03/2013	18/06/2024	791471	9845439	1695
Rio Verde (16)	Baños	4086	06/02/2013	14/04/2024	800465	9845046	1529
U. E. Pedro Fermín (17)	Cevallos	3906	13/03/2013	21/11/2023	765641	9849972	2910
Pampas de Salasaca (18)	Mocha	3905	13/03/2013	20/11/2023	757194	9844510	3760
Huambaló (19)	Pelileo	3763	23/02/2013	13/06/2023	774743	9846179	2800

¹ La numeración de estaciones servirá para identificarlas en el mapa de ubicación.

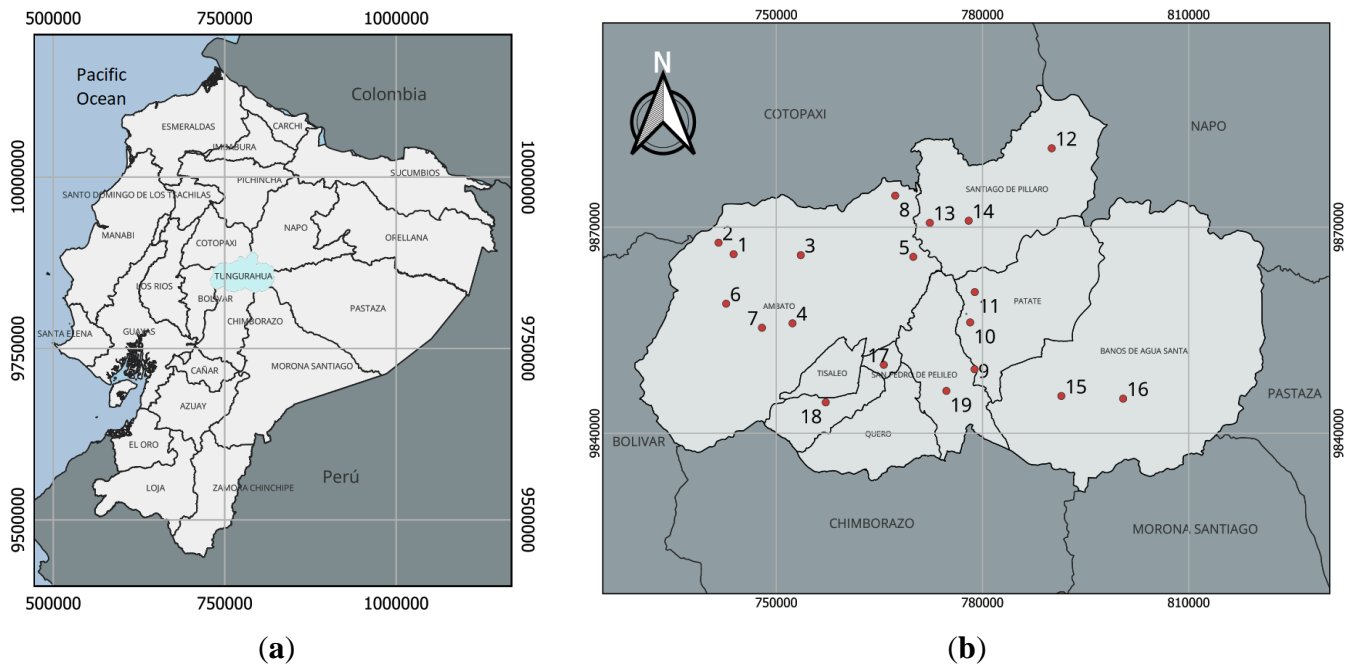


Figura 1. Ubicación del área de estudio: (a) Mapa del Ecuador, donde se muestra la provincial de Tungurahua; (b) Distribución espacial de las estaciones meteorológicas en la provincia de Tungurahua.

Tratamiento de datos

Durante la verificación inicial de los datos se identificaron valores faltantes. Para evitar discontinuidades de las series temporales, estos valores se imputaron utilizando información proveniente de la base de datos NASA-POWER (NASA POWER Project, 2025), seleccionando los registros diarios correspondientes a la misma ubicación geográfica y fechas específicas. Este procedimiento permitió sustituir datos ausentes con valores de referencia consistentes, manteniendo la estructura temporal de cada serie sin distorsionar su comportamiento pluviométrico.

Medidas de localización y dispersión

Se calcularon indicadores estadísticos descriptivos con el fin de caracterizar las series temporales de precipitación. Entre estos se incluyeron: Media aritmética, mediana, cuartiles, desviación estándar y rango intercuartílico (Ridwan et al., 2021). Estas medidas permitieron identificar la distribución general de las precipitaciones, su variabilidad y la presencia de posibles asimetrías por cada estación.

Prueba de estacionariedad

La estacionariedad de cada serie se evaluó mediante la prueba KPSS (Kwiatkowski – Phillips – Schmidt - Shin), utilizada en (Unnikrishnan & Jothiprakash, 2020), con el objetivo de determinar si las precipitaciones fluctuaban alrededor de una tendencia o media constante.

Las hipótesis fueron:

H0: La serie es estacionaria.

H1: Existe raíz unitaria en la serie.

Mediante la obtención del “p-valor” la regla de decisión adoptada fue:

p-valor ≥ 0.05 --- No se rechaza H0.

p-valor < 0.05 --- Se rechaza H0.

Considerando un nivel de significancia de $\alpha = 0.05$, mismo valor empleado en (Abdaki et al., 2023; Unnikrishnan & Jothiprakash, 2020; Pulzara Mora & Losada Losada, 2023; Chipindu et al., 2023; Basak et al., 2022; Ning et al., 2022)

Modelo Prophet

El modelo Prophet (Taylor & Letham, 2017), es un modelo de predicción de series temporales, basado en la descomposición aditiva de series temporales horarias, diarias, semanales y mensuales.

Su estructura permite modelar series no estacionarias con múltiples patrones de tendencia y estacionalidad. El comportamiento general puede representarse como:

$$Y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (1)$$

Donde:

g(t): Componente de tendencia, modelada mediante funciones lineales con puntos de cambio. Representa los cambios a largo plazo en la serie temporal, gracias a puntos de cambio (change points), los cuales permiten capturar modificaciones abruptas en el comportamiento de la serie temporal.

s(t): Componente estacional que modela patrones repetitivos dentro del año.

h(t): Componente de efectos de ocurrencia irregular.

ε_t : Componente aleatorio no explicado por los términos anteriores.

2.1 Métricas de Evaluación

Las métricas de evaluación empleadas fueron la Raíz del Error Cuadrático Medio “RMSE” y el Error Absoluto Medio “MAE”, sustentadas en (Abdaki et al., 2023; Rogers et al., 2024; Li et al., 2023; Ridwan et al., 2021; Kwarteng & Andreevich, 2024; Pulzara Mora & Losada Losada, 2023), (Chipindu et al., 2023; Basak et al., 2022; Ning et al., 2022; Sulasikin et al., 2021; Armando et al., n.d.; Hossain et al., 2022). Las ecuaciones correspondientes a las métricas mencionadas se reportan a continuación:

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3)$$

Donde:

- n: Es el número total de observaciones en el conjunto de prueba.
- y_i : Es el valor observado real.
- \hat{y}_i : Es el valor pronosticado por el modelo Prophet.

2.2 División de datos

Para analizar la influencia del tamaño del conjunto de entrenamiento en el desempeño predictivo del modelo univariante Prophet, se establecieron tres esquemas de segmentación de los datos históricos de precipitación. Las divisiones consideradas están sustentadas en (Rogers et al., 2024; Li et al., 2023; Ridwan et al., 2021; Sulasikin et al., 2021), siendo estas:

- 80% de los datos para entrenamiento y 20% para prueba.
- 85% de los datos para entrenamiento y 15% para prueba.
- 90% de los datos para entrenamiento y 10% para prueba.

Cada esquema de división fue aplicado de manera independiente a las series temporales correspondientes a las 19 estaciones meteorológicas analizadas. La partición de los datos se realizó respetando estrictamente el orden cronológico de las observaciones, garantizando que el conjunto de prueba estuviera conformado exclusivamente por datos posteriores en el tiempo respecto al conjunto de entrenamiento. En consecuencia, el modelo Prophet fue entrenado únicamente con los datos del conjunto de entrenamiento y posteriormente evaluado sobre el conjunto de prueba correspondiente a cada división, sin que este último participe en ninguna etapa de ajuste.

Optimización de hiperparámetros

Con la finalidad de mejorar el desempeño predictivo del modelo univariante Prophet, se ejecutó un proceso de optimización de hiperparámetros mediante “Búsqueda por cuadrícula (grid search)”. Este procedimiento permitió evaluar de forma sistemática distintas combinaciones de hiperparámetros y seleccionar aquella que minimizara el error de pronóstico en el conjunto de prueba.

Los hiperparámetros ajustados fueron “changepoint prior scale” y “seasonality prior scale” empleados en (Abdaki et al., 2023; Ning et al., 2022), debido a su influencia directa sobre la flexibilidad de la tendencia y amplitud de la estacionalidad. El primer hiperparámetro controla la sensibilidad del modelo ante cambios estructurales en la serie temporal, sus valores pueden variar entre 0.05 a 10, valores elevados permiten que la tendencia sea más flexible y se ajuste más a los datos, mientras que valores reducidos favorecen una tendencia más suave. Por su parte, “seasonality prior scale” regula la magnitud de las oscilaciones estacionales, permitiendo que la estacionalidad se ajuste a grandes fluctuaciones al incrementar su valor de 10 a 100.

La selección de la configuración óptima se realizó comparando valores obtenidos de MAE y RMSE en el conjunto de prueba. Este enfoque permitió evaluar la contribución del ajuste de hiperparámetros al rendimiento del modelo, en comparación con los resultados obtenidos utilizando los valores predeterminados de Prophet.

Resultados y discusión

En esta sección se presentan los resultados obtenidos a partir de la aplicación del modelo univariante Prophet a las series temporales de precipitación correspondientes a las 19 estaciones meteorológicas analizadas. Los resultados se organizan conforme a los componentes metodológicos descritos previamente, con el objetivo de mostrar de manera clara y estructurada el comportamiento de los datos y el desempeño del modelo.

Medidas de localización y dispersión

La **¡Error! No se encuentra el origen de la referencia.** presenta las medidas de localización y dispersión correspondientes a las series temporales de precipitación diaria de las 19 estaciones meteorológicas analizadas. En general, los resultados evidencian una elevada variabilidad en los registros de precipitación, reflejada principalmente en los valores de desviación estándar y en la amplitud entre los valores mínimos y máximos.

Las medias aritméticas de precipitación diaria muestran diferencias significativas entre estaciones, con valores que oscilan entre 1.20 mm en la estación “Hacienda Cunchibamba” y 7.94 mm en Río Verde. De manera consistente, la mediana en la mayoría de las estaciones se mantiene por debajo de la media, lo que indica una distribución asimétrica positiva asociada a la ocurrencia de eventos de precipitación intensa poco frecuentes.

En cuanto a la dispersión, se observa desviaciones estándar elevadas en estaciones como “Río Verde” y “U. E. Benjamín Araujo”, lo que manifiesta una alta irregularidad en los registros diarios. Pues, los valores máximos registrados en estas estaciones corresponden a 225 mm y 334 mm respectivamente, evidenciando la presencia de eventos extremos de precipitación.

Tabla 2. Medidas de localización y dispersión (mm).

Estación	Media Aritmética	Desviación Estándar	Valor mínimo	Mediana	Valor máximo
Chiquiurcu	2.95	4.52	0	1.1	45.4
Mula Corral	2.57	4.01	0	0.9	35.6
Quisapincha	2.66	3.98	0	1.1	39.3
Pilahuin	1.94	3.77	0	0.6	65
Aeropuerto	1.41	3.02	0	0.1	34.5
Calamaca	1.94	3.17	0	0.615	29.7
Tamboloma	1.79	3.48	0	0.3	36.4
Hacienda Cunchibamba	1.2	2.95	0	0.1	40.6
Hacienda Guadalupe	1.84	3.79	0	0.3	52
U. E. Benjamín Araujo	2.05	7.67	0	0.1	334
U. E Antonio José de Sucre	2.71	4.6	0	0.9	43.8
Embalse Pisayambo	3.59	5.29	0	1.6	53.8

U. E. Jorge Álvarez	1.49	3.01	0	0.2	37.1
Escuela Tasinteo	2.52	4.12	0	0.9	46.7
Parque de la Familia Baños	3.56	6.14	0	0.7	63.5
Rio Verde	7.94	14	0	3.7	255
U. E. Pedro Fermín Cevallos	1.29	2.73	0	0.1	30.9
Pampas de Salasaca	2.7	4.1	0	1.1	45.8
Huambaló	2.43	5.67	0	0.6	177

¹ La unidad de los valores mostrados en la tabla son milímetros mm.

Prueba de Estacionariedad

La **Tabla 1** presenta los resultados de la prueba de estacionariedad aplicada a las series temporales de precipitación diaria de las 19 estaciones meteorológicas analizadas.

Tabla 1. Prueba de Estacionariedad.

Estación	p-valor	$\alpha = 0.05$	Regla de decisión	Resultado
Chiquiurcu	0.0896	0.05	$0.0896 > 0.05$	La serie es estacionaria
Mula Corral	0.1	0.05	$0.1 > 0.05$	La serie es estacionaria
Quisapincha	0.0106	0.05	$0.0106 < 0.05$	La serie es no estacionaria
Pilahuin	0.01	0.05	$0.01 < 0.05$	La serie es no estacionaria
Aeropuerto	0.01	0.05	$0.01 < 0.05$	La serie es no estacionaria
Calamaca	0.1	0.05	$0.1 > 0.05$	La serie es estacionaria
Tamboloma	0.1	0.05	$0.1 > 0.05$	La serie es estacionaria
Hacienda Cunchibamba	0.0663	0.05	$0.0663 > 0.05$	La serie es estacionaria
Hacienda Guadalupe	0.0939	0.05	$0.0939 > 0.05$	La serie es estacionaria
U. E. Benjamín Araujo	0.01	0.05	$0.01 < 0.05$	La serie es no estacionaria
U. E. Antonio José de Sucre	0.1	0.05	$0.1 > 0.05$	La serie es estacionaria
Embalse Pisayambo	0.01	0.05	$0.01 < 0.05$	La serie es no estacionaria
U. E. Jorge Álvarez	0.1	0.05	$0.1 > 0.05$	La serie es estacionaria
Escuela Tasinteo	0.0943	0.05	$0.0943 > 0.05$	La serie es estacionaria
Parque de la Familia Baños	0.01	0.05	$0.01 < 0.05$	La serie es no estacionaria
Rio Verde	0.01	0.05	$0.01 < 0.05$	La serie es no estacionaria
U. E. Pedro Fermín Cevallos	0.01	0.05	$0.01 < 0.05$	La serie es no estacionaria
Pampas de Salasaca	0.01	0.05	$0.01 < 0.05$	La serie es no estacionaria
Huambaló	0.01	0.05	$0.01 < 0.05$	La serie es no estacionaria

Los p – valores obtenidos evidencian que una proporción importante de las series no cumple con el criterio de estacionariedad, al presentar valores inferiores al umbral establecido. En estas estaciones, la hipótesis nula fue rechazada, indicando la presencia de cambios en la media y/o en la tendencia a lo largo del tiempo.

De manera general, 10 estaciones presentaron valores de p menores a 0.05, por lo que sus series fueron clasificadas como no estacionarias. Por otro lado, las 9 estaciones faltantes mostraron valores de p superiores al nivel de significancia, indicando un comportamiento estacionario bajo el criterio de la prueba aplicada.

Estos resultados confirman la coexistencia de series estacionarias y no estacionarias dentro del conjunto de datos analizado, reflejando la heterogeneidad del comportamiento pluviométrico entre estaciones y justificando la aplicación de modelos de pronósticos capaces de manejar series no estacionarias.

Optimización de hiperparámetros y métricas de evaluación

La **Tabla 2** presenta los mejores valores obtenidos de las métricas de evaluación MAE y RMSE, junto con la configuración óptima de hiperparámetros del modelo Prophet para cada una de las estaciones meteorológicas analizadas. En este contexto, se evaluaron diferentes divisiones de datos y se aplicó un proceso de optimización mediante búsqueda por cuadrícula, con el objetivo de identificar la combinación de parámetros que minimizara el error de pronóstico.

Los resultados evidencian que, en la mayoría de las estaciones, la división de datos 90% para entrenamiento y 10% para prueba produjo los mejores valores de error, confirmando un mejor desempeño del modelo cuando se dispone de una mayor cantidad de información histórica. No obstante, en algunas estaciones, las divisiones 85% - 15% y 80% - 20% presentaron resultados comparables, lo que refleja la variabilidad inherente de las series de precipitación.

Tabla 2. Mejores valores de hiperparámetros y métricas de evaluación.

Estación	MAE (mm)	RMSE (mm)	División de datos	Método de búsqueda	Changepoint prior scale	Seasonality prior scale
Chiquiurcu	2.9275	4.7694	90% y 10%	Búsqueda por cuadrícula	10	100
Mula Corral	2.2774	3.8387	85% y 15%	Búsqueda por cuadrícula	10	20
Quisapincha	2.2724	2.9115	90% y 10%	Búsqueda por cuadrícula	10	80
Pilahuin	1.7182	1.9566	90% y 10%	Búsqueda por cuadrícula	10	10
Aeropuerto	1.3329	2.5486	90% y 10%	Búsqueda por cuadrícula	0.5	80
Calamaca	1.8649	2.8726	90% y 10%	Búsqueda por cuadrícula	10	10
Tamboloma	1.7445	3.8474	85% y 15%	Búsqueda por cuadrícula	0.1	0.001
H. Cunchibamba	1.0398	1.8956	85% y 15%	Valores Prophet	0.05	10
H. Guadalupe	1.9210	3.3746	80% y 20%	Búsqueda por cuadrícula	0.05	0.001
U. E. Benjamín Araujo	2.1998	3.4860	90% y 10%	Búsqueda por cuadrícula	10	10

U. E A. José de Sucre	2.3129	2.9904	85% y 15%	Búsqueda por cuadrícula	0.05	10
Embalse Pisayambo	2.7672	5.0408	80% y 20%	Búsqueda por cuadrícula	0.05	100
U. E. Jorge Álvarez	1.3839	2.0778	90% y 10%	Búsqueda por cuadrícula	0.05	80
Escuela Tasinteo	2.2797	3.9165	85% y 15%	Búsqueda por cuadrícula	0.05	100
Parque de la Familia	2.8171	4.7711	85% y 15%	Búsqueda por cuadrícula	10	80
Rio Verde	3.8012	6.3168	85% y 15%	Búsqueda por cuadrícula	10	0.001
U. E. P. Fermín Cevallos	1.9017	2.7242	90% y 10%	Búsqueda por cuadrícula	10	10
Pampas de Salasaca	2.3898	3.7330	90% y 10%	Valores Prophet	0.05	10
Huambaló	1.5155	2.1994	90% y 10%	Búsqueda por cuadrícula	10	10

En relación con la optimización de hiperparámetros, se observa que el método de búsqueda por cuadrícula permitió mejorar el ajuste del modelo en la mayoría de las estaciones, principalmente mediante el ajuste del parámetro “change point prior scale”, el cual adoptó valores tanto bajos como elevados dependiendo del comportamiento de la serie temporal. Asimismo, el parámetro “seasonality prior scale” mostró una amplia variabilidad entre estaciones, evidenciando diferencias en la intensidad de los patrones estacionales.

Cabe destacar que en un número reducido de estaciones como “Hacienda Cunchibamba” y “Pampas de Salasaca”, los mejores resultados se obtuvieron utilizando los valores predeterminados de Prophet, lo que indica que el modelo puede ofrecer un desempeño adecuado incluso sin un proceso de optimización adicional.

De manera general, los valores de MAE y RMSE obtenidos confirman que el modelo Prophet logra un ajuste satisfactorio en el pronóstico diario de precipitaciones; sin embargo, se observan incrementos en el RMSE en estaciones con mayor variabilidad y presencia de eventos extremos, lo cual es consistente con la naturaleza enrevesada de la precipitación.

Con el fin de ilustrar el comportamiento del modelo, se presentan gráficas representativas de 5 estaciones, seleccionadas en función de su variabilidad y desempeño. En primer lugar, se escogieron 3 estaciones distintas, cada una asociada a un porcentaje de división de datos diferente, en las que se obtuvieron los mejores resultados. Adicionalmente, se incluyó una estación cuyo mejor desempeño se alcanzó utilizando los valores predeterminados de Prophet y, finalmente, una estación con un registro histórico limitado, con el propósito de evitar la saturación de figuras y la reiteración de resultados de gráficos similares y al mismo tiempo exponer el comportamiento del modelo ante distintos escenarios identificados en esta investigación, de acuerdo con las características de los datos analizados.

Los resultados obtenidos en este estudio aportan evidencia sobre el comportamiento local de las precipitaciones y el desempeño del modelo univariante Prophet aplicado a series temporales pluviométricas mismo que no es homogéneo, tal como se muestran en la **Tabla 2**, estaciones como Embalse Pisayambo **Figura 7**, U. E. José de Sucre **Figura 6**, Tamboloma **Figura 5**, Chiquiurcu **Figura 4** y Pampas de Salasaca

Figura 3.



Además, en estaciones como Río Verde, Embalse Pisayambo, U.E. Benjamín Araujo se registraron valores de RMSE relativamente elevados, coherentes con la alta dispersión y la presencia de máximos de precipitación identificados en la **¡Error! No se encuentra el origen de la referencia.** En contraste, estaciones como Hacienda Cunchibamba, Pilahuin o Aeropuerto presentan menores valores de MAE y RMSE, asociados a una variabilidad más moderada de la precipitación diaria.

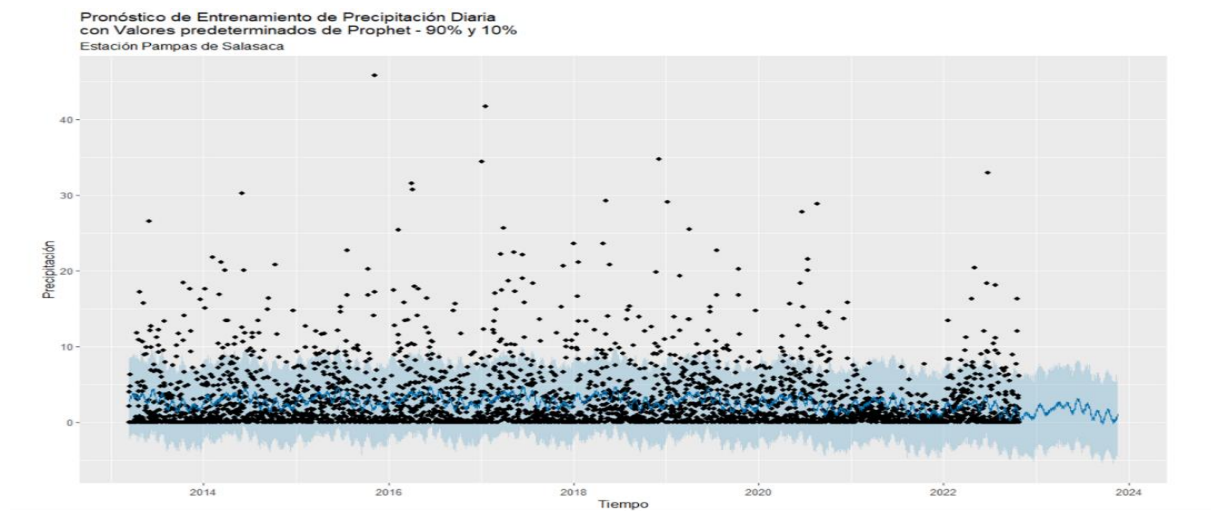


Figura 3. Pronóstico de entrenamiento de la estación Pampas de Salasaca con valores predeterminados de Prophet.

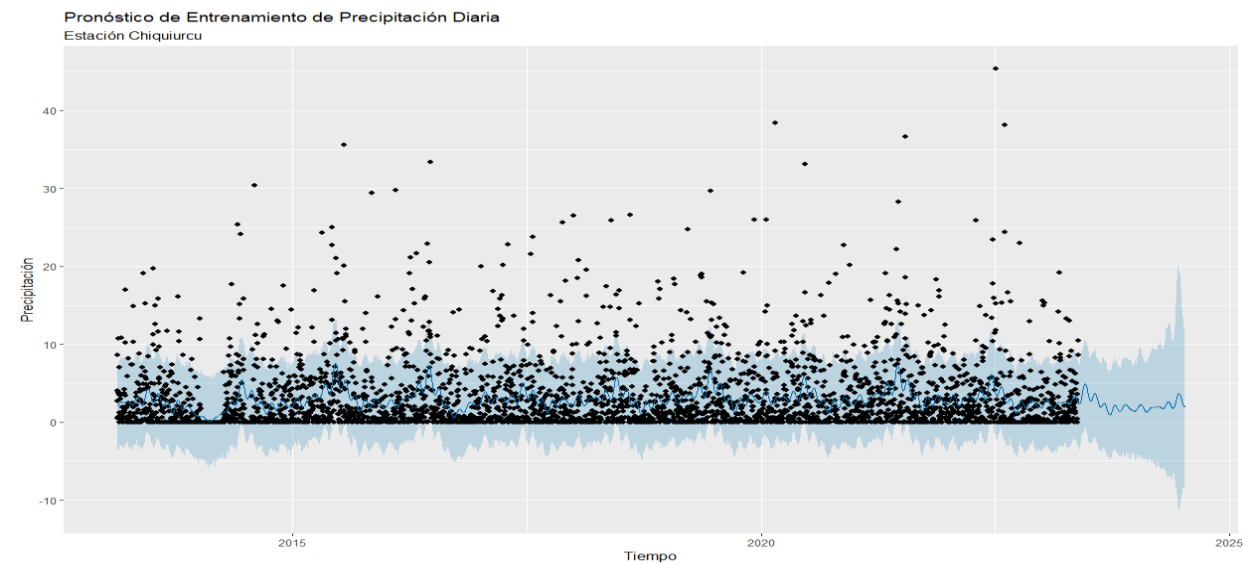


Figura 4. Pronóstico de entrenamiento de la estación Chiquiurcu con segmentación de 90% y 10% y valores de hiperparámetros encontrados por búsqueda por cuadrícula.




Figura 5. Pronóstico de entrenamiento de la estación Tamboloma con segmentación de 85% y 15% y valores de hiperparámetros encontrados por búsqueda por cuadrícula.

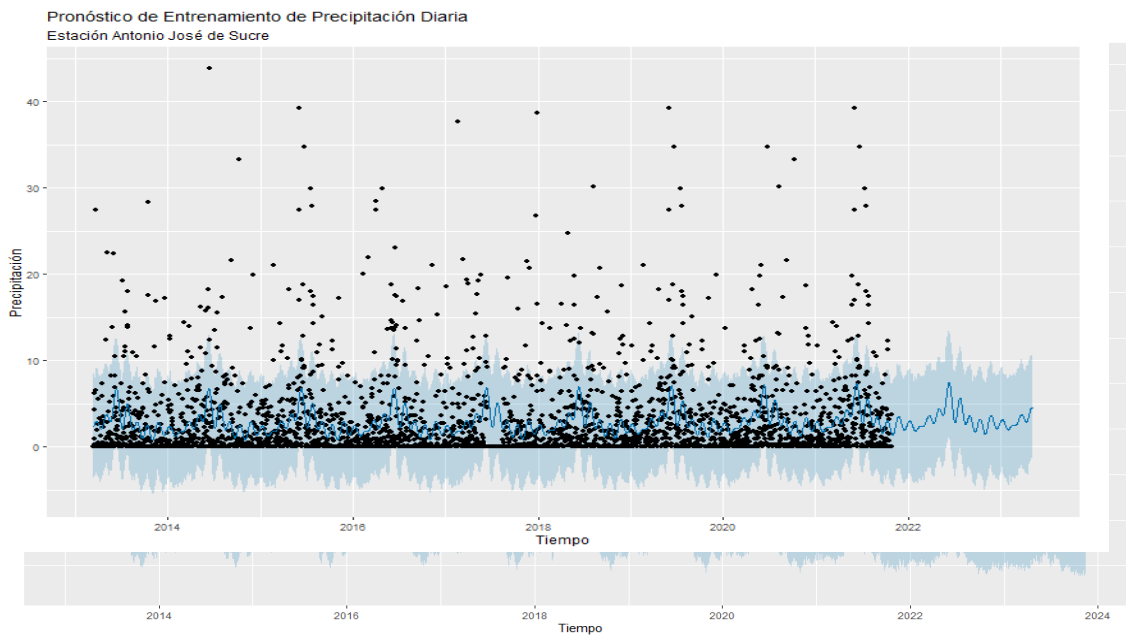


Figura 6. Pronóstico de entrenamiento de la estación Antonio José de Sucre con segmentación de 85% y 15% y valores de hiperparámetros encontrados por búsqueda por cuadrícula.




Figura 7. Pronóstico de entrenamiento de la estación Embalse Pisayambo con segmentación de 80% y 20% y valores de hiperparámetros encontrados por búsqueda por cuadrícula.

Este comportamiento sugiere que cada estación depende de condiciones climáticas y características topográficas locales que generan patrones de precipitación distintos, mismos que deben considerarse al emplear el modelo Prophet, concordando así con lo expuesto por Abdaki et al. (Abdaki et al., 2023), quienes presentaron diferencias de rendimiento debido a la naturaleza local de los patrones de lluvia, heterogeneidad espacial, ubicación geográfica y elevación, puntos importantes a considerar al predecir precipitaciones.

En la Figura 5 se observa el comportamiento del modelo trabajando con la serie temporal de la estación Tamboloma, evidenciándose una línea casi recta descendente, exhibiendo fluctuaciones mínimas y con poca adaptación a las características y particularidades de la serie, este comportamiento puede deberse a la poca cantidad de datos disponibles en esta estación, afectando la etapa de entrenamiento del modelo.

En contraste, en las estaciones Pampas de Salasaca, Chiquiurcu, Antonio José de Sucre y Embalse Pisayambo el ajuste y entrenamiento del modelo Prophet fue sobresaliente, evidenciando una notable capacidad para reproducir las tendencias de las series temporales. Estos resultados respaldan lo expuesto por Abdaki et al. (Abdaki et al., 2023), Sulasikin et al. (Sulasikin et al., 2021), Pulzara et al. (Pulzara Mora & Losada Losada, 2023), Kwarteng et al. (Kwarteng & Andreevich, 2024), quienes determinaron que Prophet tiende a capturar patrones específicos y tendencias definidas, ajustándose mejor que otros modelos estocásticos, exhibiendo un rendimiento superior al registrar valores de error más bajos.

Además, es importante exponer el análisis comparativo de las tres segmentaciones de datos evaluadas 80% - 20%, 85% - 15% y 90% - 10%, pues en 10 de las 19 de las estaciones, el uso del 90% de los datos para entrenamiento y 10% para prueba conduce a menores errores de pronóstico, tanto en términos de MAE como de RMSE presentados en la Tabla 2. Este patrón sugiere que un mayor volumen de información histórica permite a Prophet capturar con mayor precisión las tendencias y ciclos estacionales de la precipitación, especialmente en estaciones con alta variabilidad interanual.

Sin embargo, en estaciones como Embalse Pisayambo, Hacienda Guadalupe, Tamboloma o Escuela Tasinteo, las mejores métricas se obtienen con divisiones 80%-20% o 85%-15%, lo que indica que la relación entre tamaño del conjunto de entrenamiento y desempeño no es estrictamente monótona y depende También de la estructura interna de cada serie. Estos resultados coinciden con los señalados por Basak et al. (Basak et al., 2022), quienes evidenciaron que la exactitud de los pronósticos mejora al aumentar la escala temporal destinada al entrenamiento, independientemente del modelo utilizado en su investigación.

A pesar del buen ajuste global, las gráficas de entrenamiento revelan que Prophet tiende a subestimar o suavizar las precipitaciones máximas diarias. En estaciones como Embalse Pisayambo, Río Verde y U. E. Benjamín Araujo se observan picos de precipitación que superan ampliamente al resto de estaciones, lo cual se plasma en valores elevados de RMSE frente a MAE expuestos en la Tabla 2. Reforzando este comportamiento se observó que en todas las estaciones el modelo tuvo complicaciones para predecir precipitaciones máximas. Este comportamiento observado coincide con lo documentado por Dongsheng et al. (Li et al., 2023) y Hossain et al. (Hossain et al., 2022) en estudios previos, donde mencionan que los resultados del pronóstico del modelo Prophet para precipitaciones máximas fueron deficientes.

En contraste el modelo presenta un desempeño notablemente mejor en la representación de periodos secos o de baja precipitación. Principalmente en las estaciones Pampas de Salasaca y Tamboloma se aprecian intervalos con predominio de valores cercanos a cero. Tal como lo señalan Abdaki et al. (Abdaki et al., 2023), Hossain et al. (Hossain et al., 2022) y Basak et al. (Basak et al., 2022), quienes documentaron que Prophet alcanza una mayor precisión al pronosticar episodios de sequía, caracterizados por lapsos prolongados con precipitaciones por debajo de la media.

Conclusiones

Los resultados obtenidos evidencian que el modelo univariante Prophet constituye una herramienta viable para el pronóstico de la precipitación diaria, al reproducir de manera satisfactoria el comportamiento general de las series analizadas. El modelo mostró una buena capacidad para capturar la dinámica y los patrones estaciones de la lluvia, especialmente en los rangos bajos y medios de precipitación, reforzando su potencial para aplicaciones relacionadas con la planificación y gestión del recurso hídrico en contextos andinos. Por otro lado, el análisis de las diferentes particiones de datos permitió comprobar que el desempeño de Prophet mejora cuando se dispone de un mayor volumen de información histórica para entrenamiento.

En particular, las configuraciones 85-15% y 90-10% se asociaron a los mejores resultados en la mayoría de las estaciones, lo que subraya la relevancia de una selección cuidadosa del porcentaje de datos destinados a

entrenamiento y validación en estudios de pronósticos hidrometeorológicos. De forma complementaria, la optimización de los hiperparámetros vinculados a la tendencia y a la estacionalidad mediante búsqueda por cuadrícula demostró ser una estrategia eficaz para reducir los errores de pronóstico frente al uso exclusivo de los valores predeterminados del modelo. De esta manera, estos hallazgos posicionan a Prophet como una alternativa sólida para el apoyo a la toma de decisiones en infraestructura, agricultura y gestión Ambiental, siempre que se disponga de series temporales de calidad y longitud suficiente. Así mismo, los resultados obtenidos ofrecen una base cuantitativa para el desarrollo de investigaciones futuras orientadas a comparar el desempeño de Prophet con otros enfoques de modelación y metodologías que permitan abordar las limitaciones en el pronóstico de eventos extremos de precipitación.

Agradecimientos

Los autores agradecen el soporte de la Dirección de Investigación y Desarrollo de la Universidad Técnica de Ambato para el desarrollo de este proyecto de investigación, código PFICM31 “Pronóstico de precipitaciones en la provincia de Tungurahua usando modelación estocástica.” Aprobado mediante resolución UTA-CONIN-2023-0292-R.

Referencias

- Salih, S. Q., Sharafati, A., Khosravi, K., Fiza, M., Yaseen, Z. M., Inyurt, S., Bateni, S. M., Shahid, S., & Yaseen, Z. M. (2020). Integrative stochastic model standardization with genetic algorithm for rainfall pattern forecasting in tropical and semi-arid environments. *Hydrological Sciences Journal*, 65(7), 1145–1157. <https://doi.org/10.1080/02626667.2020.1734813>
- Xu, L., Chen, N., Zhang, X., & Chen, Z. (2020). A data-driven multi-model ensemble for deterministic and probabilistic precipitation forecasting at seasonal scale. *Climate Dynamics*, 54(7–8), 3355–3374. <https://doi.org/10.1007/s00382-020-05173-x>
- Li, Y., Niu, Z., Liu, C., & Yan, C. (2022). Credible Bayesian reliability model for structures with interval uncertain parameters. *Structures*, 45, 2151–2161. <https://doi.org/10.1016/j.istruc.2022.09.058>
- Saha, A., Singh, K. N., Ray, M., & Rathod, S. (2020). A hybrid spatio-temporal modelling: An application to space-time rainfall forecasting. *Theoretical and Applied Climatology*, 142(3–4), 1271–1282. <https://doi.org/10.1007/s00704-020-03374-2>
- Buhl, M., & Markolf, S. (2023). A review of emerging strategies for incorporating climate change considerations into infrastructure planning, design, and decision making. *Sustainable and Resilient Infrastructure*, 8(Suppl. 1), 157–169. <https://doi.org/10.1080/23789689.2022.2134646>
- Chen, L., et al. (2025). Global increase in the occurrence and impact of multiyear droughts. *Science*, 387(6731), 278–284. <https://doi.org/10.1126/science.ado4245>
- Yaseen, Z. M., Ali, M., Sharafati, A., Al-Ansari, N., & Shahid, S. (2021). Forecasting standardized precipitation index using data intelligence models: Regional investigation of Bangladesh. *Scientific Reports*, 11(1), Article 3435. <https://doi.org/10.1038/s41598-021-82977-9>
- Ashok, S. P., & Pekkatt, S. (2022). A systematic quantitative review on the performance of some of the recent short-term rainfall forecasting techniques. *Journal of Water and Climate Change*, 13(8), 3004–3029. <https://doi.org/10.2166/wcc.2022.302>

- CRED. (2025a). Disaster year in review 2024. Centre for Research on the Epidemiology of Disasters. <https://files.emdat.be/2025/05/CredCrunch78.pdf>
- CRED. (2025b). Hydrological disasters in South America. Centre for Research on the Epidemiology of Disasters. https://files.emdat.be/reports/2024_EMDAT_report.pdf
- Abdaki, M., Al-Ozeer, A. Z. A., Alobaydy, O., & Al-Tayawi, A. N. (2023). Predicting rainfall in Nineveh Governorate in northern Iraq using machine learning time-series forecasting algorithm. *Arabian Journal of Geosciences*, 16(12), Article 655. <https://doi.org/10.1007/s12517-023-11779-2>
- Saenz-Lituma, G. (2025). The agroecological transition of farms in the Ecuadorian Andes through the lens of the main agroecological structure. *Land Degradation & Development*, 36(2), 424–440. <https://doi.org/10.1002/ldr.5368>
- Operador Nacional de Electricidad CENACE. (2025). Informe Anual CENACE 2024. CENACE.
- Rodríguez-Gallegos, C. D., Gandhi, O., Rodríguez-Gallegos, C. A., & Alvarez-Alvarado, M. S. (2025). Co-location potential of floating PV with hydropower plants: Case study in Ecuador. *Solar*, 5(1), Article 3. <https://doi.org/10.3390/solar5010003>
- Ebtehaj, I., Bonakdari, H., Zeynoddin, M., Gharabaghi, B., & Azari, A. (2020). Evaluation of preprocessing techniques for improving the accuracy of stochastic rainfall forecast models. *International Journal of Environmental Science and Technology*, 17(1), 505–524. <https://doi.org/10.1007/s13762-019-02361-z>
- Khaniani, A. S., Motieyan, H., & Mohammadi, A. (2021). Rainfall forecast based on GPS PWV together with meteorological parameters using neural network models. *Journal of Atmospheric and Solar-Terrestrial Physics*, 214, Article 105533. <https://doi.org/10.1016/j.jastp.2020.105533>
- Sheikh, M. R., & Coulibaly, P. (2024). Review of recent developments in hydrologic forecast merging techniques. *Water*, 16(2), Article 301. <https://doi.org/10.3390/w16020301>
- Katumo, E., Katila, C., Omolo, R., & Ken, H. (2025). A drought forecasting model using the Prophet time series analysis technique. *Indian Journal of Computer Science and Technology*, 290–294. <https://doi.org/10.59256/indjst.20250402038>
- Rogers, J. K. B., Mercado, T. C. R., & Galleto, F. A., Jr. (2024). Comparison of ARIMA boost, Prophet boost, and TSLM models in forecasting Davao City weather data. *Indonesian Journal of Electrical Engineering and Computer Science*, 34(2), 1092–1101. <https://doi.org/10.11591/ijeecs.v34.i2.pp1092-1101>
- Pérez-Alarcón, A., Garcia-Cortes, D., Fernández-Alvarez, J. C., & Martínez-González, Y. (2022). Improving monthly rainfall forecast in a watershed by combining neural networks and autoregressive models. *Environmental Processes*, 9(3), Article 53. <https://doi.org/10.1007/s40710-022-00602-x>
- Duan, X., Ma, R., & Zhang, X. (2022). Forecasting occurrence and quantity of monthly precipitation simultaneously while accounting for complex serial correlation. *International Journal of Climatology*, 42(16), 9494–9509. <https://doi.org/10.1002/joc.7839>
- Lana, X., Rodríguez-Solà, R., Martínez, M. D., Casas-Castillo, M. C., Serra, C., & Kirchner, R. (2021). Autoregressive process of monthly rainfall amounts in Catalonia (NE Spain) and improvements on predictability of length and intensity of drought episodes. *International Journal of Climatology*, 41(S1). <https://doi.org/10.1002/joc.6915>
- Dahiya, P., et al. (2024). Time series study of climate variables utilising a seasonal ARIMA technique for the Indian states of Punjab and Haryana. *Discover Applied Sciences*, 6(12), Article 650. <https://doi.org/10.1007/s42452-024-06380-5>

- Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37–45. <https://doi.org/10.1080/00031305.2017.1380080>
- Hossain, M. M., Anwar, A. H. M. F., Garg, N., Prakash, M., & Bari, M. (2022). Monthly rainfall prediction at catchment level with the Facebook Prophet model using observed and CMIP5 decadal data. *Hydrology*, 9(6), Article 111. <https://doi.org/10.3390/hydrology9060111>
- Bosson-Amedenu, S., Baah, E. M., Ayiah-Mensah, F., & Addor, J. A. (2025). Advanced time series modelling to address seasonal variability and extreme rainfall in Ghana. *BMC Environmental Science*, 2(1), Article 8. <https://doi.org/10.1186/s44329-025-00024-8>
- Hossain, M. A., Rahman, M. M., Hasan, S. S., Mahmud, A., & Bai, L. (2025). Analysis and forecasting of meteorological drought using PROPHET and SARIMA models deploying machine learning technique for southwestern region of Bangladesh. *Environmental and Sustainability Indicators*, 27, Article 100761. <https://doi.org/10.1016/j.indic.2025.100761>
- Ning, Y., Kazemi, H., & Tahmasebi, P. (2022). A comparative machine learning study for time series oil production forecasting: ARIMA, LSTM, and Prophet. *Computers & Geosciences*, 164, Article 105126. <https://doi.org/10.1016/j.cageo.2022.105126>
- Abdaki, M., Al-Ozeer, A. Z. A., Alobaydy, O., & Al-Tayawi, A. N. (2023). Predicting rainfall in Nineveh Governorate in northern Iraq using machine learning time-series forecasting algorithm. *Arabian Journal of Geosciences*, 16(12), Article 655. <https://doi.org/10.1007/s12517-023-11779-2>
- Rogers, J. K. B., Mercado, T. C. R., & Galleto, F. A., Jr. (2024). Comparison of ARIMA boost, Prophet boost, and TSLM models in forecasting Davao City weather data. *Indonesian Journal of Electrical Engineering and Computer Science*, 34(2), 1092–1101. <https://doi.org/10.11591/ijeecs.v34.i2.pp1092-1101>
- Li, D., et al. (2023). Prediction of rainfall time series using the hybrid DWT-SVR-Prophet model. *Water*, 15(10), Article 1935. <https://doi.org/10.3390/w15101935>
- Ridwan, W. M., Sapitang, M., Aziz, A., Kushiari, K. F., Ahmed, A. N., & El-Shafie, A. (2021). Rainfall forecasting model using machine learning methods: Case study Terengganu, Malaysia. *Ain Shams Engineering Journal*, 12(2), 1651–1663. <https://doi.org/10.1016/j.asej.2020.09.011>
- Unnikrishnan, P., & Jothi Prakash, V. (2020). Hybrid SSA-ARIMA-ANN model for forecasting daily rainfall. *Water Resources Management*, 34(11), 3609–3623. <https://doi.org/10.1007/s11269-020-02638-w>
- Suárez-Aguilar, Z. E., Sepúlveda-Delgado, O., Patarroyo-Mesa, M., & Canaria-Camargo, L. C. (2020). Mathematical model to estimate curves of intensity, duration and frequency of extreme rains in Tunja, Colombia. *Informacion Tecnológica*, 31(1), 193–206. <https://doi.org/10.4067/S0718-07642020000100193>
- Kwarteng, S., & Andreevich, P. (2024). Comparative analysis of ARIMA, SARIMA and Prophet model in forecasting. *Research & Development*, 5(4), 110–120. <https://doi.org/10.11648/j.rd.20240504.13>
- NASA POWER Project. (2025). NASA prediction of worldwide energy resources (POWER) project. NASA. <https://power.larc.nasa.gov/data-access-viewer/>
- Pulzara Mora, C. A., & Losada Losada, J. D. (2023). Análisis de series temporales en estaciones meteorológicas para la predicción de la precipitación en la ciudad de Manizales, Colombia. *Revista de Climatología*, 23, 58–70. <https://doi.org/10.59427/rcli/2023/v23.58-70>

- Chipindu, L., Mupangwa, W., Nyagumbo, I., & Zaman-Allah, M. (2023). Unsupervised segmentation and clustering time series approach to Southern Africa rainfall regime changes. *Geoscience Data Journal*. <https://doi.org/10.1002/gdj3.228>
- Basak, A., Rahman, A. T. M. S., Das, J., Hosono, T., & Kisi, O. (2022). Drought forecasting using the Prophet model in a semi-arid climate region of western India. *Hydrological Sciences Journal*, 67(9), 1397–1417. <https://doi.org/10.1080/02626667.2022.2082876>
- Ning, Y., Kazemi, H., & Tahmasebi, P. (2022). A comparative machine learning study for time series oil production forecasting: ARIMA, LSTM, and Prophet. *Computers & Geosciences*, 164, Article 105126. <https://doi.org/10.1016/j.cageo.2022.105126>
- Taylor, S. J., & Letham, B. (2017). Forecasting at scale (PeerJ Preprints 3190v2). *PeerJ*. <https://doi.org/10.7287/peerj.preprints.3190v2>
- Sulasikin, A., Nugraha, Y., Kanggrawan, J. I., & Suherman, A. L. (2021). Monthly rainfall prediction using the Facebook Prophet model for flood mitigation in Central Jakarta. In *Proceedings of the 8th International Conference on ICT for Smart Society (ICISS 2021)*. IEEE. <https://doi.org/10.1109/ICISS53185.2021.9532507>
- Armando, J., et al. (n.d.). Estimation of average monthly rainfall with multiple linear regression and artificial neural networks in a semi-arid basin. [Unpublished manuscript].
- Hossain, M. M., Anwar, A. H. M. F., Garg, N., Prakash, M., & Bari, M. (2022). Monthly rainfall prediction at catchment level with the Facebook Prophet model using observed and CMIP5 decadal data. *Hydrology*, 9(6), Article 111. <https://doi.org/10.3390/hydrology906011>