

**PRONÓSTICO MULTIMODELO DE CONSUMO DE AGUA EN RIOBAMBA CON
VARIABLES EXÓGENAS (TEMPERATURA Y PRECIPITACIÓN).
MULTI-MODEL FORECASTING CONSUMPTION IN RIOBAMBA USING EXOGENOUS
VARIABLES (TEMPERATURE AND PRECIPITATION).**

Autores: ¹Fernanda Anahy Cáceres Núñez y ²Guillermo Edwin Machado Sotomayor.

¹ORCID ID: <https://orcid.org/0009-0001-2550-7655>

²ORCID ID: <https://orcid.org/0000-0001-5226-468X>

¹E-mail de contacto: anahy.caceres@unach.edu.ec

²E-mail de contacto: gmachado@unach.edu.ec

Afiliación:^{1*}^{2*}Universidad Nacional de Chimborazo, (Ecuador).

Artículo recibido: 17 de Abril del 2026

Artículo revisado: 19 de Abril del 2026

Artículo aprobado: 21 de Abril del 2026

¹Matemática, egresada de la Escuela Superior Politécnica de Chimborazo, (Ecuador). Maestrante de la Maestría en Matemática Aplicada con mención en Matemática Computacional en la Universidad Nacional de Chimborazo, (Ecuador).

²Doctor en Matemática, egresado de la Escuela Superior Politécnica de Chimborazo, (Ecuador). Magíster en Formulación, Evaluación y Gestión de Proyectos Sociales y Productivos, egresado de la Universidad Nacional de Chimborazo, (Ecuador). Magíster en Educación Matemática, egresado de la Universidad Nacional de Chimborazo, (Ecuador). Dottore di Ricerca in Matematica e Informatica, egresado de la Università de Ila Calabriado, (Italia). Docente de la Universidad Nacional de Chimborazo (Ecuador).

Resumen

La previsión del consumo de agua potable constituye una herramienta clave para fortalecer la planificación operativa de los sistemas urbanos de abastecimiento. En este contexto, el presente estudio tuvo como objetivo desarrollar y evaluar un esquema multimodelo para el pronóstico mensual del consumo de agua potable en el cantón Riobamba, a partir de registros históricos por red de distribución y subredes, incorporando variables exógenas de temperatura y precipitación. La investigación se desarrolló bajo un enfoque cuantitativo, con diseño no experimental, longitudinal y retrospectivo. La base de consumo fue depurada, agregada por ruta y mes, e integrada con información climática mensual obtenida de una fuente abierta continua. Posteriormente, se seleccionaron subredes piloto con series completas y consistentes, y se ajustaron comparativamente los modelos SARIMAX, Prophet y XGBoost, evaluando su desempeño mediante métricas de error sobre un conjunto de prueba temporal. Los resultados evidenciaron que el comportamiento predictivo varió según la subred analizada, sin identificarse un modelo universalmente superior para todos los casos. No obstante, XGBoost mostró el mejor desempeño global, mientras que SARIMAX y Prophet resultaron

más adecuados en subredes con patrones específicos de consumo.

Palabras clave: Pronóstico, Demanda de agua, Multimodelo, SARIMAX, Prophet, XGBoost.

Abstract

Forecasting potable water consumption is a key tool for strengthening the operational planning of urban water supply systems. In this context, the present study aimed to develop and evaluate a multi-model scheme for monthly potable water consumption forecasting in the Riobamba canton, based on historical records for the distribution network and sub-networks, incorporating exogenous variables of temperature and precipitation. The research was conducted using a quantitative approach, with a non-experimental, longitudinal, and retrospective design. The consumption data base was refined, aggregated by route and month, and integrated with monthly climate information obtained from a continuous open source. Subsequently, pilot sub-networks with complete and consistent series were selected, and the SARIMAX, Prophet, and XGBoost models were comparatively fitted, evaluating their performance using error metrics on a time-series test set. The results showed that predictive performance varied depending on the sub-network analyzed, without identifying

a universally superior model for all cases. However, XGBoost showed the best overall performance, while SARIMAX and Prophet proved more suitable for subnetworks with specific consumption patterns.

Keywords: Forecasting, Water demand, Multimodel, SARIMAX, Prophet, XGBoost.

Sumário

A previsão do consumo de água potável é uma ferramenta fundamental para o aprimoramento do planejamento operacional dos sistemas de abastecimento de água urbanos. Nesse contexto, o presente estudo teve como objetivo desenvolver e avaliar um esquema multimodelos para a previsão mensal do consumo de água potável no cantão de Riobamba, com base em registros históricos da rede de distribuição e sub-redes, incorporando variáveis exógenas de temperatura e precipitação. A pesquisa foi conduzida utilizando uma abordagem quantitativa, com delineamento não experimental, longitudinal e retrospectivo. O banco de dados de consumo foi refinado, agregado por rota e mês, e integrado com informações climáticas mensais obtidas de uma fonte aberta e contínua. Posteriormente, sub-redes piloto com séries temporais completas e consistentes foram selecionadas, e os modelos SARIMAX, Prophet e XGBoost foram ajustados comparativamente, avaliando-se seu desempenho por meio de métricas de erro em um conjunto de teste de séries temporais. Os resultados mostraram que o desempenho preditivo variou de acordo com a sub-rede analisada, sem identificar um modelo universalmente superior para todos os casos. Contudo, o XGBoost apresentou o melhor desempenho geral, enquanto o SARIMAX e o Prophet se mostraram mais adequados em sub-redes com padrões de consumo específicos.

Palavras-chave: Previsão da demanda de água, multimodelos, SARIMAX, Prophet, XGBoost.

Introducción

La previsión de la demanda de agua potable se ha consolidado como un componente central de la gestión operativa de los sistemas urbanos de abastecimiento, debido a que permite anticipar requerimientos de producción, almacenamiento, bombeo, control de presiones y uso eficiente de energía. En ese sentido, los trabajos de Bakker et al. (2013) y Romano y Kapelan (2014) mostraron que el pronóstico de la demanda no constituye únicamente un ejercicio estadístico, sino una herramienta directamente vinculada con la operación en tiempo casi real y con la mejora del desempeño de los sistemas de distribución. Más recientemente, Lin et al. (2025) reiteraron que la precisión del pronóstico condiciona la racionalidad de la programación y la sostenibilidad del uso del recurso, incluso cuando se trabaja a distintas escalas temporales.

La complejidad de este problema radica en que el consumo de agua urbana no depende de un solo factor, sino de la interacción entre memoria temporal, clima, calendario, comportamiento del usuario, características del sistema y escala de observación. El estudio de House-Peters & Chang (2011) ya advirtió que la modelación de demanda urbana debía entenderse como un campo metodológicamente plural, donde convergen enfoques econométricos, estadísticos, hidrológicos y espaciales. Posteriormente, Tiwari y Adamowski (2013) evidenciaron que variables como la temperatura máxima y la precipitación total pueden mejorar la exactitud del pronóstico, mientras que Abu Talib et al. (2023) mostraron que la relevancia de los factores exógenos cambia según el contexto, e incluso puede alterarse de forma marcada ante perturbaciones como la pandemia. En una escala más amplia, Hao et al. (2025) encontraron que la demanda urbana mensual a escala de ciudad está fuertemente determinada

por la memoria de corto plazo, aunque las variables climáticas también cumplen un papel explicativo importante. En cuanto a los métodos de pronóstico, la literatura muestra una evolución clara desde modelos estadísticos tradicionales hacia esquemas comparativos que incorporan aprendizaje automático y aprendizaje profundo.

Los modelos de la familia ARIMA y SARIMA siguen siendo ampliamente utilizados por su parsimonia y capacidad para representar dependencia temporal, especialmente cuando las series presentan una estructura relativamente estable; sin embargo, su rendimiento puede disminuir cuando predominan relaciones no lineales o interacciones complejas entre predictores. Al mismo tiempo, revisiones recientes han señalado que los métodos basados en inteligencia artificial han ampliado notablemente el repertorio de soluciones disponibles, pero sin eliminar la necesidad de comparación rigurosa entre enfoques. En particular, Niknam et al. (2022) y Ghannam y Hussain (2024) coincidieron en que no existe un modelo universalmente superior para todos los contextos de demanda de agua, y que la elección metodológica debe responder a la resolución temporal, la longitud de la serie, la disponibilidad de predictores y la finalidad operativa del estudio.

Asimismo, Kavya et al. (2023) y Bata et al. (2020) mostraron, en contextos diferentes, que la comparación entre modelos estadísticos, híbridos y de aprendizaje automático sigue siendo una estrategia necesaria cuando se busca identificar alternativas robustas para gestión real. Junto con esta evolución metodológica, han emergido nuevas líneas de investigación centradas en la multiescala, la incertidumbre y la interpretabilidad. En el estudio de Papacharalampous y Langousis (2022)

propusieron algoritmos probabilísticos para pronósticos de demanda urbana, subrayando que la utilidad de un modelo no depende solo de un valor puntual, sino también de la capacidad para representar incertidumbre. En paralelo, Maußner et al. (2025) destacaron que la confiabilidad y la aplicabilidad del modelo son cada vez más importantes para su adopción en sistemas de abastecimiento, especialmente cuando las decisiones operativas son sensibles al error.

De forma complementaria, Que et al. (2024) y Lin et al. (2025) mostraron que en redes con múltiples distritos o subáreas la estructura espacial y temporal de la demanda puede aprovecharse mediante arquitecturas más complejas, aunque ese incremento de sofisticación no necesariamente implica superioridad universal. En otras palabras, la literatura más reciente no solo empuja hacia modelos más potentes, sino también hacia comparaciones más rigurosas, más contextualizadas y más orientadas a la utilidad práctica del pronóstico. Otro aspecto ampliamente discutido es el papel de las variables exógenas. La evidencia acumulada sugiere que factores meteorológicos como temperatura y precipitación pueden mejorar la capacidad predictiva, pero su efecto depende de la escala espacial, del horizonte temporal y de la forma en que se integran con la historia de consumo.

En esa línea, Xenochristou et al. (2020) demostraron que la exactitud del pronóstico y la importancia relativa de los predictores cambian de manera sustantiva con la escala espacial del análisis, mientras que Pesantez et al. (2020) mostraron que, a nivel de usuario, la incorporación de datos meteorológicos y características del hogar puede mejorar el desempeño cuando se dispone de medición

inteligente. En el plano aplicado, Abu et al. (2023) confirmaron que los factores exógenos no actúan de manera uniforme y que su contribución debe analizarse en función del contexto operativo, lo que refuerza la conveniencia de utilizar configuraciones multivariadas y comparativas en estudios empíricos.

En Ecuador, entre los antecedentes publicados localizados se encuentra el trabajo de Gortaire et al. (2016), quienes desarrollaron, calibraron y validaron un modelo matemático para pronosticar la demanda real de agua potable en Quito a partir de una serie de 2557 datos de caudales medios diarios entregados por la planta de tratamiento de agua potable Bellavista. Ese antecedente es relevante porque demuestra la factibilidad de trabajar con datos institucionales reales en el contexto ecuatoriano y de incorporar variables meteorológicas, urbanísticas, demográficas y económicas dentro del problema de pronóstico. Sin embargo, el caso del cantón Riobamba plantea una situación distinta, ya que el estudio se construye con información organizada por red de distribución y subredes, en una escala mensual, y con interés aplicado de apoyar la planificación operativa del sistema local.

En ese sentido, el caso de Riobamba no solo amplía la evidencia empírica nacional, sino que permite examinar el comportamiento comparativo de tres familias metodológicas diferentes bajo una estructura de datos coherente con la operación real del sistema. Bajo esta perspectiva, este estudio tuvo como objetivo desarrollar y evaluar un esquema multimodelo (SARIMAX, Prophet y XGBoost) para el pronóstico mensual del consumo de agua potable en Riobamba, a partir de registros históricos por red de distribución y subredes, incorporando variables exógenas de

temperatura y precipitación, a fin de apoyar la planificación operativa de producción y distribución. De manera específica, el estudio buscó integrar una base histórica de consumo y clima, ajustar comparativamente los tres modelos seleccionados e identificar cuál ofreció el mejor desempeño según el comportamiento de cada subred piloto. Con ello, la investigación aporta evidencia aplicada para Riobamba y, al mismo tiempo, se inserta en una discusión metodológica más amplia sobre la conveniencia de comparar modelos estadísticos, aditivos y de boosting en sistemas de agua potable con escalas subagregadas y series mensuales.

Metodología

La investigación se desarrolló en el cantón Riobamba, provincia de Chimborazo, Ecuador, bajo un enfoque cuantitativo, de tipo aplicado, con alcance descriptivo, comparativo y predictivo, y mediante un diseño no experimental, longitudinal y retrospectivo. El estudio se orientó al pronóstico mensual del consumo de agua potable a partir de registros históricos del sistema de distribución, por lo que no existió manipulación experimental de las variables observadas. La información institucional reportó que los registros del sistema se organizan por red de distribución y sus respectivas subredes, que la toma de datos se efectúa mediante ciclos de lectura en días específicos de cada mes, que la unidad de medida del consumo es en m^3 y que el estado del dato se clasifica institucionalmente como Normal. En consecuencia, la escala temporal metodológicamente coherente para el análisis fue mensual, y el horizonte de predicción se definió como el siguiente periodo mensual de lectura. La base principal de consumo correspondió al periodo marzo de 2024 a febrero de 2026 e incluyó 1,048,500 registros individuales. En el archivo original estaban disponibles las variables mes, año, consumo,

categoría, ciclo, ruta, dirección, medidor, valor_con_basura y valor_sin_basura. No obstante, dado que el objetivo del estudio fue pronosticar el comportamiento del consumo físico de agua y no analizar la facturación, la variable de interés se definió a partir de consumo, mientras que los campos monetarios se excluyeron del modelado. Asimismo, aunque la base contenía información a nivel de registro

individual, la unidad analítica del estudio no fue el abonado o medidor, sino la ruta/subred agregada por mes, por ser la escala mínima con continuidad temporal suficiente para construir series comparables y coherentes con la estructura operativa del sistema. La Tabla 1 resume las fuentes de información y su papel en el estudio.

Tabla 1. Fuentes de información empleadas en el estudio

Fuente	Período	Resolución original	Variables utilizadas	Uso en el estudio
Base institucional de consumo del sistema de agua potable de Riobamba	marzo 2024-febrero 2026	Registro individual	mes, año, consumo, ciclo, ruta	Construcción de series mensuales por ruta/subred
NASA POWER Daily API	marzo 2024-febrero 2026	Diaria	T2M, T2M_MAX, T2M_MIN, PRECTOTCORR	Construcción de variables climáticas mensuales

Fuente: Elaboración propia

La base de consumo fue sometida a un proceso secuencial de revisión, depuración y agregación. En una primera etapa se verificó la integridad de las variables mes, año, ciclo y ruta, así como la coherencia general del archivo. Posteriormente, se identificaron registros con consumo igual a cero y con consumo negativo. Los valores iguales a cero se conservaron dentro de la base, debido a que formaban parte del registro institucional y podían corresponder a lecturas válidas del sistema; en cambio, los valores negativos se consideraron observaciones inconsistentes para control de calidad y se tomaron en cuenta en la selección de subredes piloto. Después de esta revisión, los registros individuales fueron agregados por ruta/subred y mes, sumando todos los consumos correspondientes a una misma ruta en un mismo período. La agregación se realizó mediante la ecuación 1:

$$C_{r,t} = \sum_{i=1}^{n_{r,t}} c_{i,r,t} \quad (1)$$

donde $C_{r,t}$ representa el consumo total mensual de la ruta r en el mes t ; $c_{i,r,t}$ corresponde al consumo del registro i asociado a esta ruta y ese mes, y $n_{r,t}$ es el número de registros disponibles en dicha combinación. A partir de esta transformación se generó una tabla agregada con las variables año, mes, fecha_mes, ruta, consumo_mensual_m3, registros, n_consumos_cero y n_consumos_negativos. La variable fecha_mes se definió como el primer día de cada mes y se utilizó como referencia temporal única para ordenar las series. Las variables climáticas se obtuvieron de Nasa Power Daily Api, un servicio que distribuye datos meteorológicos diarios listos para análisis y que permite recuperar series continuas de temperatura y precipitación para coordenadas específicas. Para este estudio se empleó un punto representativo del cantón Riobamba, con coordenadas latitud -1.6743472 y longitud -78.6482944, y se descargaron las variables T2M, T2M_MAX, T2M_Min y Protector para todo el periodo analizado. Esta fuente fue seleccionada para evitar la combinación de

varios repositorios climáticos en tramos distintos y asegurar así homogeneidad metodológica en toda la serie.

Una vez descargada la información climática diaria, esta fue agregada a escala mensual para hacerla compatible con la base de consumo. La temperatura media mensual se calculó como el promedio de la temperatura media diaria del mes; la precipitación acumulada mensual se obtuvo como la suma de la precipitación diaria corregida; adicionalmente, se derivaron la temperatura máxima mensual, la temperatura mínima mensual, el número de días con lluvia y el número de días observados. Estas transformaciones se realizaron mediante las siguientes ecuaciones:

$$\bar{T}_t = \frac{1}{n_t} \sum_{d=1}^{n_t} T_{d,t} \quad (2)$$

$$P_t = \sum_{d=1}^{n_t} P_{d,t} \quad (3)$$

donde \bar{T}_t representa la temperatura media mensual del mes t , $T_{d,t}$ es la temperatura diaria observada, P_t es la precipitación acumulada mensual y $P_{d,t}$ es la precipitación diaria registrada en el día d . Posteriormente, la base climática mensual se integró con la base de consumo agregado mediante las claves año y mes, generando una base maestra única para el análisis. A partir de la base maestra se evaluó la continuidad temporal y la consistencia de las series por ruta/subred. Para seleccionar las subredes piloto se aplicaron como criterios; la disponibilidad de 24 meses completos entre marzo de 2024 y febrero de 2026; el consumo promedio positivo; la ausencia de meses con consumo total negativo; la ausencia de registros

negativos que comprometieran la consistencia global de la serie; y la representatividad de perfiles contrastantes de consumo. Con base en estos criterios se seleccionaron tres subredes piloto: Subred 12 como serie de consumo alto, Subred 26 como serie de consumo medio y Subred 34 como serie de consumo bajo. Esta decisión permitió comparar el desempeño de los modelos en comportamientos de demanda diferenciados sin cambiar la escala espacial del análisis.

Con las tres subredes seleccionadas se construyó la base final para el modelado. La variable dependiente fue consumo mensual en m^3 , expresada en metros cúbicos. Como variables predictoras se incluyeron Lag 1 y Lag 2, que representan el consumo observado uno y dos meses previos, respectivamente; la variable tendencia, definida como una secuencia temporal ordinal del 1 al 24; y el trimestre, correspondiente al periodo calendario de cada observación. Asimismo, se incorporaron covariables exógenas como la temperatura media mensual rezagada un periodo y la precipitación acumulada mensual también rezagada un periodo. Esta decisión metodológica se adoptó con el fin de evitar la fuga de información temporal, garantizando que al momento de pronosticar el consumo del mes t solo se utilice información disponible hasta el mes $t-1$. Por otro lado, la variable variación mensual porcentual se calculó únicamente con fines descriptivos, por lo que no fue considerada en el ajuste del modelo final. La Tabla 2 presenta un resumen de la definición operativa de todas las variables incluidas en el estudio.

Tabla 2. Variables utilizadas en el modelado.

Variable	Tipo	Descripción	Unidad	Función en el análisis
Consumo mensual_m3	Dependiente	Consumo mensual agregado por ruta/subred	m ³	Variable objetivo
lag_1	Predictora	Consumo del mes anterior	m ³	Captura persistencia total
lag_2	Predictora	Consumo de dos meses antes	m ³	Captura dependencia temporal adicional
tendencia	Predictora	Secuencia temporal ordinal de la serie	Adimensional	Captura evolución temporal
Trimestre	Predictora	Trimestre calendario de cada observación	Adimensional	Representa efecto interanual
Temperatura media mensual_c_lag1	Predictora exógena	Temperatura media mensual rezagada un periodo	°C	Captura influencia climática disponible al momento del pronóstico
Precipitación acumulada mensual mm_lag1	Predictora exógena	Precipitación mensual acumulada rezagada un periodo	mm	Captura influencia climática disponible al momento del pronóstico

Fuente: Elaboración propia

La construcción de lag_1, lag_2 y de las covariables climáticas rezagadas generó valores faltantes estructurales al inicio de cada serie. Por ello, antes del ajuste se eliminaron las filas con valores faltantes en cualquiera de las variables predictoras o en la variable objetivo. Como cada subred disponía de 24 observaciones mensuales, el número efectivo de observaciones útiles para modelado fue de 22 por subred. El procesamiento, la depuración y el ajuste de los modelos se realizaron en Python dentro de un entorno de Google Colab. Para la manipulación de datos se utilizó la biblioteca panda; el ajuste del modelo autorregresivo se llevó a cabo con statsmodels; el modelo descomponible se implementó con prophet; y el modelo de boosting se desarrolló mediante xgboost.

En total, se ajustaron tres enfoques: SARIMAX, Prophet y XGBoost. El modelo SARIMAX se configuró con una especificación parsimoniosa (1, 0, 0), sin componente estacional explícito, e incorporó como variables exógenas la temperatura media mensual rezagada un periodo y la precipitación acumulada mensual también rezagada. Esta elección respondió a la

limitada longitud de las series disponibles para el entrenamiento y al interés de mantener configuraciones comparables entre las subredes analizadas. Por su parte, el modelo Prophet se ajustó considerando únicamente estacionalidad anual, sin incluir componentes semanales ni diarios, e integró los mismos regresores exógenos rezagados. Su uso permitió contrastar un enfoque metodológico distinto al de los modelos autorregresivos tradicionales.

En cuanto al modelo XGBoost, se implementó mediante el estimador XGBRegressor, configurado con función objetivo de error cuadrático, 200 estimadores, profundidad máxima de 3, tasa de aprendizaje de 0,05, fracciones de muestreo de 0,8 tanto para observaciones como para variables, un parámetro de regularización de 1,0 y una semilla aleatoria fija para garantizar reproducibilidad. Este modelo fue seleccionado por su capacidad para capturar relaciones no lineales y estructuras complejas entre rezagos, tendencias y variables exógenas, lo que lo convierte en una alternativa robusta frente a los enfoques tradicionales. La configuración principal de los modelos se resume en la Tabla

3. El ajuste se realizó por subred, es decir, cada una de las tres series se modeló de forma independiente. Para cada subred, las 22 observaciones útiles se ordenaron cronológicamente y se dividieron en un conjunto de entrenamiento y un conjunto de prueba, conservando el orden temporal. El conjunto de entrenamiento estuvo compuesto por las primeras 18 observaciones, mientras que el conjunto de prueba se conformó con las últimas 4 observaciones mensuales. No se utilizaron particiones aleatorias, porque en series temporales este procedimiento puede inducir fuga de información y producir estimaciones artificialmente optimistas del error (Hewamalage et al., 2022). El desempeño de cada modelo se evaluó mediante MAE, RMSE y MAPE, calculados sobre el conjunto de prueba. Estas métricas se obtuvieron empleando las siguientes ecuaciones:

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (5)$$

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (6)$$

donde y_t representa el valor observado, \hat{y}_t el valor pronosticado y n el número de observaciones del conjunto de prueba. El uso conjunto de estas tres métricas se adoptó para obtener una evaluación complementaria del error, en concordancia con las recomendaciones de buenas prácticas para evaluación de pronósticos. Para cada subred y para cada modelo se generaron dos salidas, una tabla de métricas de desempeño, con los valores de MAE, RMSE y MAPE; y una tabla de predicciones, con las variables ruta, modelo, fecha_mes, observado y pronosticado. Ambas salidas se exportaron en formatos CSV y Excel, con el fin de facilitar la trazabilidad del procedimiento.

Tabla 3. Configuración de los modelos de pronóstico.

Modelo	Implementación	Variables de entrada	Configuración principal
SARIMAX	statsmodels	Consumo rezagado y covariables exógenas rezagadas	order = (1, 0, 0), seasonal_order = (0, 0, 0, 0)
Prophet	prophet	Serie mensual y covariables exógenas rezagadas	yearly_seasonality=True, weekly_seasonality=False, daily_seasonality=False
XGBoost	xgboost	lag_1, lag_2, tendencia, trimestre, temperatura rezagada y precipitación rezagada	n_estimators=200, max_depth=3, learning_rate=0.05, subsample=0.8, colsample_bytree=0.8

Fuente: Elaboración propia

Resultados y Discusión

La evaluación predictiva se realizó sobre tres subredes piloto del sistema de agua potable del cantón Riobamba, la Subred 12, la Subred 26 y la Subred 34. En todos los casos se trabajó con series mensuales correspondientes al periodo marzo de 2024 a febrero de 2026, utilizando las últimas cuatro observaciones como conjunto de prueba. Este diseño permitió comparar, bajo una misma partición temporal y con el mismo conjunto de predictoras, el comportamiento de

SARIMAX, Prophet y XGBoost en subredes con distinto nivel de consumo. Desde una perspectiva descriptiva, como se observa en la Tabla 4, la Subred 12 concentró el mayor volumen acumulado del periodo analizado, con 1,011,342 m³, equivalente al 65.15% del volumen total de las tres subredes piloto. La Subred 26 registró 333,072 m³ (21.46%) y la Subred 34 alcanzó 207,820 m³ (13.39%). Sin embargo, la magnitud del volumen no fue el único rasgo distintivo. La Subred 12 presentó

también la menor variabilidad relativa, con un coeficiente de variación de 4.04%, mientras que la Subred 26 y la Subred 34 registraron 7.01% y 6.65%, respectivamente. Esta diferencia es relevante porque la literatura ha mostrado que la precisión del pronóstico de demanda de agua

varía con la escala espacial, la agregación de la serie y su regularidad interna, de modo que las series más estables suelen generar mejores niveles de ajuste que aquellas con oscilación relativa (Ghannam y Hussain, 2024; Xenochristou et al., 2020).

Tabla 4. Estadísticos descriptivos de las subredes piloto.

Subred	Meses	Consumo acumulado (m ³)	Promedio mensual (m ³)	Mínimo (m ³)	Máximo (m ³)	Desv. Estándar	CV (%)
Subred 12	24	1011.342	42139.25	39.269	44.594	1702.52	4.04
Subred 26	24	333.072	13878.00	11.833	15.398	973.46	7.01
Subred 34	24	207.820	8659.17	7.472	9.729	576.06	6.65

Fuente: Elaboración propia

La comparación del desempeño predictivo como se muestra en la Tabla 5, mostró que no existió un modelo universalmente superior en las tres subredes, sino que la precisión dependió del comportamiento específico de cada serie y la forma en que se incorporaron las variables explicativas y exógenas. Por ello, las revisiones contemporáneas recomiendan contrastar enfoques de naturaleza distinta antes de seleccionar una solución operativa (Ghannam y Hussain, 2024; Xenochristou et al., 2020).

aproximadamente 13.3% respecto del modelo autorregresivo. Este resultado sugiere que, en la subred de mayor magnitud y baja variabilidad relativa, un algoritmo de boosting fue capaz de aprovechar mejor la combinación entre rezagos de consumo, tendencia y covariables climáticas rezagadas. Esta lectura es consistente con estudios que han mostrado ventajas de los enfoques basados en boosting cuando la precisión depende de interacciones no lineales y de la combinación entre historia de consumo y factores contextuales (Abu Talib et al., 2023).

Tabla 5. Desempeño predictivo de los modelos por subred.

Subred	Modelo	MAE	RMSE	MAPE (%)
Subred 12	Prophet	46689.41	50844.08	113.39
	SARIMAX	1868.66	2099.56	4.56
	XGBoost	1664.09	2012.06	3.95
Subred 26	Prophet	923.76	1061.51	7.42
	SARIMAX	1368.00	1711.19	11.25
	XGBoost	1034.91	1304.79	8.52
Subred 34	Prophet	6042.02	6838.64	73.01
	SARIMAX	691.02	896.70	8.89
	XGBoost	708.04	923.58	9.13

Fuente: Elaboración propia

En la subred 12, el mejor desempeño correspondió a XGBoost, con un MAE de 1,664.09, un RMSE de 2,012.06 y un MAPE de 3.95%. Aunque SARIMAX también presentó un ajuste satisfactorio, con un MAPE de 4.56%, XGBoost redujo el error porcentual en

En esa misma subred, Prophet mostró un comportamiento claramente deficiente, con un MAPE de 113.39%, acompañado además de predicciones físicamente no plausibles en parte del tramo de prueba, incluyendo valores negativos. Dado que el consumo de agua no puede asumir valores menores a cero, este resultado evidencia que el modelo aditivo no logró representar adecuadamente la dinámica de la serie. Aunque Prophet fue diseñado para modelar tendencia, estacionalidad y efectos adicionales de forma interpretable, su desempeño depende de que esas componentes se ajusten razonablemente a la estructura observada; en series cortas o con señal insuficiente para estabilizar la descomposición, la respuesta puede volverse errática (Maußner

et al., 2025). En la subred 26, el patrón fue distinto. En este caso, Prophet alcanzó el mejor desempeño, con un MAE de 923.76, un RMSE de 1,061.51 y un MAPE de 7.42% superando tanto a XGBoost (8.52%) como a SARIMAX (11.25%). Este resultado indica que el modelo aditivo sí logró capturar razonablemente la trayectoria reciente de una serie de magnitud intermedia y oscilación moderada. En términos interpretativos, esto confirma que el comportamiento de Prophet no fue uniformemente deficiente, sino dependiente del perfil de la subred. La literatura reciente ha insistido precisamente en que la utilidad de un modelo de pronóstico de demanda de agua no debe juzgarse de forma abstracta, sino según la estructura concreta de la serie, la escala analizada y la combinación de predictores disponibles (Abu et al., 2023; Ghannam y Hussain, 2024).

En la subred 34, el mejor resultado correspondió a SARIMAX, que obtuvo un MAE de 691.02 un RMSE de 896.70 y un MAPE de 8.89%. Aunque XGBoost mostró un desempeño muy cercano, con un MAPE de 9.13%, la ligera ventaja de SARIMAX sugiere que, en una serie de menor magnitud y con una estructura temporal relativamente más simple, un modelo parsimonioso basado en dependencia autorregresiva puede ser tan eficaz como un algoritmo más flexible. Este hallazgo es metodológicamente relevante, porque coincide con la evidencia que advierte que una mayor complejidad algorítmica no garantiza automáticamente mejor rendimiento, en especial cuando el tamaño muestral y la señal histórica es relativamente estable (Bakker et al., 2014; Gil et al., 2024). En la misma subred, Prophet volvió a presentar errores excesivamente altos, con un MAPE de 73.01%. En conjunto con lo observado en la Subred 12, esto indica que la estabilidad de Prophet fue

más frágil que la de los otros dos enfoques dentro del contexto específico de Riobamba. No obstante, dado que sí fue el mejor modelo de la Subred 26, la interpretación más adecuada no es descartarlo de forma absoluta, sino reconocer que su desempeño fue altamente sensible a la estructura local de la serie. Esta heterogeneidad coincide con la discusión actual en la literatura de pronósticos, que enfatiza la necesidad de evaluar los modelos fuera de muestra y bajo el contexto real de aplicación, en lugar de asumir superioridad general a partir de sus propiedades teóricas (Ghannam y Hussain, 2024).

Si se considera el desempeño promedio de los modelos en las tres subredes, como se muestra en la Tabla 6, XGBoost mostró el mejor comportamiento global, SARIMAX ocupó el segundo lugar, mientras que Prophet presentó el peor resultado agregado. En términos prácticos, esto indica que XGBoost fue el modelo más robusto del conjunto piloto, aunque no necesariamente el mejor en todas las subredes. Esta pauta es coherente con investigaciones recientes que reportan que los métodos de aprendizaje automático pueden superar a los modelos estadísticos clásicos cuando la demanda presenta relaciones más complejas con sus rezagos y covariables, aunque esa ventaja no es homogénea para todas las series ni para todas las escalas (Görenekli y Gülbağ, 2024; Maußner et al., 2025).

Tabla 6. *Desempeño promedio de los modelos en las tres subredes.*

Modelo	MAE medio	RMSE medio	MAPE medio (%)
XGBoost	1135.68	1413.48	7.20
SARIMAX	1309.23	1569.15	8.24
Prophet	17885.06	19581.41	64.61

Fuente: Elaboración propia

La interpretación conjunta de los resultados permitió identificar cuatro hallazgos principales. Primero, la estabilidad de la serie influyó de forma clara en la precisión del pronóstico, ya que la Subred 12, con menor coeficiente de variación, presentó también los menores errores relativos en los modelos mejor posicionados. Segundo, XGBoost ofreció el mejor comportamiento global, lo que sugiere una ventaja práctica al capturar relaciones no lineales entre rezagos de consumo, tendencia y covariables climáticas. Tercero, SARIMAX se mantuvo como una alternativa sólida y competitiva, particularmente en la subred de menor magnitud.

Cuarto, Prophet mostró un comportamiento altamente dependiente del contexto, con un buen ajuste en una subred y resultados muy inestables en las otras dos. En conjunto, estos hallazgos respaldan la recomendación de contrastar familias metodológicas diferentes, tal como sugieren las revisiones recientes del campo (Maußner et al., 2025; Xenochristou et al., 2020). Otro aspecto relevante es el papel de las variables exógenas climáticas. Aunque el estudio no se orientó a medir de manera aislada su efecto causal, la inclusión de temperatura y precipitación mensuales rezagadas formó parte del conjunto de predictores que alimentó los tres modelos.

Estudios recientes han mostrado que la contribución de estas covariables depende del contexto operativo, del horizonte temporal y del grado de agregación espacial, y que su utilidad suele aumentar cuando se combinan con consumos pasados y variables temporales, más que cuando se utilizan de forma aislada. Por ello, el hecho de que XGBoost y, en una subred, Prophet, hayan respondido mejor que SARIMAX en determinados casos puede estar relacionado con una mejor explotación conjunta

de rezagos y señal climática disponible (Abu et al., 2023; Bakker et al., 2014). Aun así, los resultados deben interpretarse con prudencia. Cada subred contó con 24 meses observados, pero la incorporación de rezagos redujo la muestra útil a 22 observaciones por serie, y la evaluación final se realizó sobre 4 meses. Esto no invalida la comparación, pero sí limita el alcance inferencial de las conclusiones. Las buenas prácticas de evaluación de pronósticos insisten en que, en series cortas, la preservación del orden temporal, la selección adecuada de las métricas y la interpretación cuidadosa de los errores son esenciales para evitar conclusiones sobredimensionadas (Hewamalage et al., 2022).

Desde una perspectiva aplicada, los resultados tienen implicaciones directas para la gestión del sistema de agua potable del cantón Riobamba. La evidencia obtenida sugiere que no conviene adoptar un único modelo para todas las subredes sin considerar su perfil de consumo. En subredes de mayor estabilidad y mayor volumen, como la Subred 12, XGBoost fue el modelo más preciso. En una subred de comportamiento intermedio, como la Subred 26, Prophet mostró el mejor ajuste. En una subred de menor magnitud y estructura más simple, como la Subred 34, SARIMAX presentó la mejor respuesta. En consecuencia, la principal contribución aplicada del estudio no radica solo en identificar un modelo ganador, sino en demostrar que la selección del modelo debe realizarse en función de la dinámica propia de cada subred (Romano y Kapelan, 2014).

Conclusiones

Los resultados obtenidos permitieron concluir que sí es viable desarrollar un esquema multimodelo para el pronóstico mensual del consumo de agua potable en el cantón Riobamba a partir de registros históricos por subred y variables exógenas climáticas

agregadas mensualmente. La integración de la base institucional de consumo con temperatura y precipitación en una sola base maestra hizo posible construir series comparables, depuradas y metodológicamente consistentes para el ajuste de SARIMAX, Prophet y XGBoost.

En términos de desempeño predictivo, se comprobó que no existió un modelo universalmente superior para todas las subredes analizadas. XGBoost presentó el mejor comportamiento global, con el menor error promedio entre los tres modelos y el mejor ajuste en la Subred 12, mientras que SARIMAX mostró el mejor desempeño en la Subred 34 y Prophet alcanzó el mejor resultado en la Subred 26. En consecuencia, la evidencia empírica indica que la selección del modelo de pronóstico debe realizarse en función de la dinámica particular de cada subred, y no mediante la adopción de un único algoritmo para todo el sistema.

Asimismo, se observó que las subredes con mayor estabilidad temporal tendieron a presentar errores de pronóstico más bajos, lo que sugiere que la regularidad del patrón de consumo constituye un factor relevante en la precisión del ajuste. En este sentido, la Subred 12, además de concentrar el mayor volumen de consumo, presentó la menor variabilidad relativa y los menores errores en los modelos mejor posicionados. Este hallazgo refuerza la idea de que la complejidad del comportamiento de la serie influye directamente en la capacidad predictiva de los modelos evaluados.

Desde una perspectiva aplicada, el estudio demuestra que el uso de técnicas de pronóstico mensual puede constituir una herramienta útil para apoyar la planificación operativa de producción y distribución del agua potable en Riobamba. La posibilidad de anticipar el

comportamiento del consumo por subred permite mejorar la toma de decisiones en contextos donde la demanda no es homogénea y donde diferentes zonas del sistema presentan patrones propios de consumo. Por tanto, los resultados obtenidos aportan una base técnica para avanzar hacia esquemas de gestión más diferenciados y sensibles a la heterogeneidad interna de la red.

Aunque los hallazgos fueron consistentes con los objetivos planteados, también debe reconocerse que el estudio se desarrolló con una longitud temporal relativamente acotada y con un conjunto piloto de tres subredes, debido a cómo se llevan los registros por parte de la entidad encargada de la gestión del agua en el cantón Riobamba. En consecuencia, se recomienda que futuras investigaciones amplíen el periodo de observación, incorporen un mayor número de subredes y evalúen configuraciones adicionales de variables exógenas y validación temporal, con el fin de fortalecer la generalización de los resultados y consolidar un esquema de pronóstico operacional para todo el sistema del cantón Riobamba.

Referencias Bibliográficas

- Abu, M., Abdallah, M., Abdeljaber, A., & Abu, O. (2023). Influence of exogenous factors on water demand forecasting models during the COVID-19 period. *Engineering Applications of Artificial Intelligence*, 117, 105617. <https://doi.org/10.1016/j.engappai.2022.105617>
- Bakker, M., Duist, H., Schagen, K., Vreeburg, J., & Rietveld, L. (2014). Improving the performance of water demand forecasting models by using weather input. *Procedia Engineering*, 70, 93–102. <https://doi.org/10.1016/j.proeng.2014.02.012>

- Bakker, M., Vreeburg, J., Schagen, K., & Rietveld, L. (2013). A fully adaptive forecasting model for short-term drinking water demand. *Environmental Modelling & Software*, 48, 141–151. <https://doi.org/10.1016/j.envsoft.2013.06.012>
- Bata, M., Carriveau, R., & Ting, D. (2020). Short-term water demand forecasting using hybrid supervised and unsupervised machine learning model. *Smart Water*, 5(1). <https://doi.org/10.1186/s40713-020-00020-y>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Ghannam, S., & Hussain, F. (2024). Short-term water demand forecasting: A review. *Australasian Journal of Water Resources*. <https://doi.org/10.1080/13241583.2024.2350102>
- Gil, A., Paneque, P., Trull, O., & Troncoso, A. (2024). Medium-term water consumption forecasting based on deep neural networks. *Expert Systems with Applications*. <https://doi.org/10.1016/j.eswa.2024.123234>
- Görenekli, K., & Gülbağ, A. (2024). Comparative analysis of machine learning techniques for water consumption prediction. *Sensors*, 24(17), 5846. <https://doi.org/10.3390/s24175846>
- Gortaire, D., Ayabaca, E., Borja, F., & Valarezo, B. (2016). Modelo para el pronóstico de la demanda de agua potable en Quito. *FIGEMPA*, 2(2), 39–50. <https://doi.org/10.29166/revfig.v1i2.883>
- Hao, W., Cominola, A., & Castelletti, A. (2025). Short-term memory and regional climate drive city-scale water demand. *Earth's Future*, 13(1). <https://doi.org/10.1029/2024ef004415>
- Hewamalage, H., Ackermann, K., & Bergmeir, C. (2022). Forecast evaluation for data scientists. *Data Mining and Knowledge Discovery*, 37(2), 788–832. <https://doi.org/10.1007/s10618-022-00894-5>
- House, L., & Chang, H. (2011). Urban water demand modeling: Review of concepts and methods. *Water Resources Research*, 47(5). <https://doi.org/10.1029/2010wr009624>
- Kavya, M., Mathew, A., Shekar, P., & P, S. (2023). Short term water demand forecasting using artificial intelligence. *Sustainable Cities and Society*, 95, 104610. <https://doi.org/10.1016/j.scs.2023.104610>
- Lin, P., Zhang, X., Gong, L., Lin, J., Zhang, J., & Cheng, S. (2025). Multi-timescale urban water demand forecasting. *Journal of Hydrology*, 651, 132599. <https://doi.org/10.1016/j.jhydrol.2024.132599>
- Maußner, C., Oberascher, M., Autengruber, A., Kahl, A., & Sitzenfrei, R. (2025). Explainable artificial intelligence for water demand forecasting. *Water Research*, 268, 122779. <https://doi.org/10.1016/j.watres.2024.122779>
- NASA. (s.f.). *Daily API – NASA POWER*. <https://power.larc.nasa.gov/docs/services/api/temporal/daily/>
- NASA. (s.f.). *Parameters – NASA POWER*. <https://power.larc.nasa.gov/docs/tutorials/parameters/>
- Niknam, A., Zare, H., Hosseininasab, H., Mostafaeipour, A., & Herrera, M. (2022). A critical review of water demand forecasting tools. *Sustainability*, 14(9). <https://doi.org/10.3390/su14095412>
- Papacharalampous, G., & Langousis, A. (2022). Probabilistic water demand forecasting using quantile regression. *Water Resources Research*, 58(6). <https://doi.org/10.1029/2021wr030216>
- Pesantez, J., Berglund, E., & Kaza, N. (2020). Smart meters data for water demand forecasting. *Environmental Modelling & Software*, 125, 104633. <https://doi.org/10.1016/j.envsoft.2020.104633>
- Que, Q., Gao, J., & Qian, Y. (2024). Water demand forecasting using neural networks. *Water Research X*, 25, 100269. <https://doi.org/10.1016/j.wroa.2024.100269>

Romano, M., & Kapelan, Z. (2014). Adaptive water demand forecasting. *Environmental Modelling & Software*, 60, 265–276. <https://doi.org/10.1016/j.envsoft.2014.06.016>

Taylor, S., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37–45. <https://doi.org/10.1080/00031305.2017.1380080>

Tiwari, M., & Adamowski, J. (2013). Urban water demand forecasting using neural networks. *Water Resources Research*,

49(10), 6486–6507. <https://doi.org/10.1002/wrcr.20517>

Xenochristou, M., Hutton, C., Hofman, J., & Kapelan, Z. (2020). Water demand forecasting accuracy using machine learning. *Water Resources Research*, 56(8). <https://doi.org/10.1029/2019wr026304>



Esta obra está bajo una licencia de **Creative Commons Reconocimiento-No Comercial 4.0 Internacional**. Copyright © **Fernanda Anahy Cáceres Núñez y Guillermo Edwin Machado Sotomayor**.

Declaraciones éticas y editoriales del artículo
Contribución de los autores (Taxonomía CRediT) Fernanda Anahy Cáceres Núñez: Conceptualización de la investigación, diseño metodológico, desarrollo del proceso investigativo, análisis formal de los datos, redacción del borrador original del manuscrito, revisión crítica del contenido científico y supervisión general del estudio. Guillermo Edwin Machado Sotomayor: Conceptualización de la investigación, diseño metodológico, desarrollo del proceso investigativo, análisis formal de los datos, redacción del borrador original del manuscrito, revisión crítica del contenido científico y supervisión general del estudio.
Declaración de conflicto de intereses Los autores declaran que no existe conflicto de intereses en relación con la investigación presentada, la autoría del manuscrito ni la publicación del presente artículo.
Declaración de financiamiento La presente investigación no recibió financiamiento específico de agencias públicas, comerciales o de organizaciones sin fines de lucro. En caso de existir financiamiento institucional o externo, este deberá ser declarado explícitamente por los autores en esta sección.
Declaración del editor El editor responsable certifica que el proceso editorial del presente artículo se desarrolló conforme a los principios de integridad científica, transparencia y buenas prácticas editoriales. El manuscrito fue sometido a un proceso de evaluación mediante revisión por pares doble ciego, garantizando la confidencialidad de la identidad de los autores y revisores durante todo el proceso de dictamen académico. Asimismo, el editor declara que el artículo cumple con los criterios científicos, metodológicos y éticos establecidos por la revista.
Declaración de los revisores Los revisores externos que participaron en la evaluación del presente manuscrito declaran haber realizado el proceso de revisión de manera objetiva, independiente y confidencial. Asimismo, manifiestan que no mantienen conflictos de interés con los autores ni con la investigación evaluada, y que sus observaciones y recomendaciones se fundamentan exclusivamente en criterios científicos, metodológicos y académicos.
Declaración ética de la investigación Los autores declaran que la investigación se desarrolló respetando los principios éticos de la investigación científica, garantizando la confidencialidad de los datos y el respeto a los participantes del estudio. En los casos en que la investigación involucre seres humanos, los procedimientos deben ajustarse a los principios éticos establecidos en la Declaración de Helsinki y a las normativas institucionales correspondientes.
Declaración sobre el uso de inteligencia artificial Los autores declaran que el uso de herramientas de inteligencia artificial, en caso de haberse utilizado durante el proceso de investigación o redacción del manuscrito, se realizó únicamente como apoyo técnico para mejorar la claridad del lenguaje o el análisis de información, manteniendo siempre la responsabilidad intelectual sobre el contenido del artículo. Las herramientas de inteligencia artificial no fueron utilizadas como autoras del manuscrito ni sustituyen la responsabilidad académica de los investigadores.
Disponibilidad de datos Los datos que respaldan los resultados de esta investigación estarán disponibles previa solicitud razonable al autor de correspondencia, respetando las normas éticas y de confidencialidad establecidas por la investigación.

