

# Evaluación del uso del aprendizaje automático para la predicción del consumo del agua potable en Panamá metropolitana

## Evaluation of the use of machine learning for the prediction of drinking water consumption in metropolitan Panama

Abigail Sanjur<sup>1</sup>, Ana Deng<sup>1</sup>, Moisés Bethancourth<sup>1</sup>, Rita Arauz<sup>2\*</sup>

<sup>1</sup>Universidad Tecnológica de Panamá, Facultad de Ingeniería Industrial, Panamá

<sup>2</sup>Universidad Tecnológica de Panamá, Departamento de Estadística y Economía, Facultad de Ingeniería Industrial, Panamá

**Fecha de recepción:** 23 de mayo de 2025. **Fecha de aceptación:** 27 de junio de 2025.

**\*Autor de correspondencia:** [rita.arauz@utp.ac.pa](mailto:rita.arauz@utp.ac.pa)

**Resumen.** La falta de agua potable en un país como Panamá donde el recurso hídrico abunda es notable debido a problemas de infraestructura y planificación proactiva. Estas tareas pueden ser mejoradas implementando nuevas tecnologías para la gestión del agua como el uso de algoritmos de aprendizaje automatizado y la inteligencia artificial. El objetivo de esta investigación consiste en la evaluación de la precisión de tres tipos de modelos de aprendizaje automático, incluyendo regresión lineal, regresión Ridge y regresión por vectores de soporte (SVR) para la predicción del consumo del agua residencial en el área metropolitana de Panamá, utilizando el consumo de agua en millar de galones como variable dependiente, además de total de clientes siendo las variables independientes. A partir de la metodología planteada, se obtuvo como resultado que el mejor modelo para predecir el consumo del agua es el modelo de regresión SVR con un coeficiente de determinación  $R^2$  ajustado 0.6178, siguiendo del modelo de regresión lineal 0.6036 y del modelo Ridge, 0.6036. Así mismo, esto se pudo comprobar con la raíz de error cuadrático medio, donde la magnitud del error del modelo SVR fue el menor. Por último, se realizó una proyección del 2024 al 2028 con el modelo de regresión por vectores de soporte (SVR), donde se obtuvo que el crecimiento del agua en el área de estudio aumentará linealmente de forma positiva a medida que los años, meses y número de clientes aumenten. Con este proyecto se demuestra la utilidad de los modelos de aprendizaje automático creando una base sólida para futuras investigaciones y busca crear conciencia para la aplicación tanto de políticas como de prácticas proactivas para garantizar un suministro sostenible de agua en los próximos años.

**Palabras clave.** Agua potable, aprendizaje automático, clientes residenciales, inteligencia artificial.

**Abstract.** The lack of potable water in a country like Panama where water resources are abundant is notable due to infrastructure and proactive planning problems. These tasks can be improved by implementing new technologies for water management such as the use of machine learning algorithms and artificial intelligence. The objective of this research is to evaluate the accuracy of three types of machine learning models, including linear regression, Ridge regression and support vector regression (SVR) for the prediction of residential water consumption in the metropolitan area of Panama, using water consumption in thousand gallons as the dependent variable, and month, year and total customers as the independent variables. Based on the proposed methodology, the best model for predicting water consumption was the SVR regression model with an adjusted  $R^2$  coefficient of determination 0.6178, followed by the linear regression model 0.6036 and the Ridge model 0.6036. Finally, a projection was made from 2024 to 2028 with the support vector regression model (SVR), where it was obtained that water growth in the study area will increase linearly in a positive way as the years, months and number of customers increase. This project demonstrates the usefulness of machine learning models by creating a solid foundation for future research and seeks to raise awareness for the implementation of both policies and proactive practices to ensure a sustainable water supply in the coming years.

**Keywords.** Drinking water, machine learning, residential customers, artificial intelligence.

## 1. Introducción

La falta de agua potable en distintas partes de Panamá es un problema constante en la sociedad panameña. Muchos ciudadanos no tienen acceso regular al agua o experimentan cortes continuos en el suministro. Según el censo de población realizado en el año 2023, se dio a conocer que el 25% de hogares carece del suministro continuo de agua potable en época seca y baja al 20% en época lluviosa. Además, la proporción de personas sin acceso directo al agua potable está alrededor del 5% [1].

Esta problemática puede deberse a diversos factores relacionados con la gestión del agua involucrando la administración y distribución de los recursos hídricos. La repartición desigual es crucial donde sectores reciben más atención y recursos que otros, adicionalmente de las infraestructuras deficientes provocadas por tuberías en mal estado, falta de mantenimiento y obsolescencia de las redes de distribución. Asimismo, en los últimos años se ha dado un gran auge tecnológico, pero ¿a qué se debe que aún no hayan utilizado nuevas tecnologías para evaluar el suministro del agua? ¿Qué se podría hacer para que estas nuevas tecnologías puedan ser implementadas y así ayudar a los ciudadanos de Panamá?

### 1.1 Marco Teórico

El aprendizaje automático o *machine learning* se define como un subconjunto de la inteligencia artificial que utiliza modelos matemáticos basados en datos de muestra para realizar tareas específicas sin instrucciones explícitas. [2] exploraron el uso de técnicas de aprendizaje automático en el modelado de la calidad del agua en ríos, destacando la importancia de comprender y predecir la calidad del agua para garantizar su seguridad y disponibilidad. El empleo de algoritmos de aprendizaje automático permite analizar grandes volúmenes de datos ambientales e identificar patrones complejos que influyen en la calidad del agua. Además, este estudio destaca la necesidad de una integración interdisciplinaria para desarrollar modelos de gestión de la calidad del agua precisos y aplicables. Este enfoque ha crecido significativamente en las últimas dos décadas y se utiliza ampliamente en diversos campos científicos y comerciales.

El tema de la inteligencia artificial puede beneficiar la sostenibilidad del agua, ya que permite a las máquinas aprender de la experiencia y mejorar su rendimiento con el tiempo; la inteligencia artificial puede realizar grandes conjuntos como datos ambientales, identificar patrones y tendencias. El artículo no se limita a la sostenibilidad del agua, sino que también se extiende a otros aspectos de la sostenibilidad ambiental. Esto incluye la agricultura sostenible,

la protección del medio ambiente, la gestión de residuos y la contaminación. La IA tiene un gran potencial para ayudar a la población a lograr un futuro más sostenible enfrentando los desafíos ambientales que deben ser abordados cada vez con mayor urgencia [3].

Para garantizar el uso sostenible del agua y preservar este recurso vital para las generaciones futuras, se han introducido tecnologías innovadoras, conocidas como sistemas inteligentes de gestión del agua. Estos sistemas se emplean ampliamente para supervisar y controlar las pérdidas en la distribución de agua, predecir la demanda de agua y evaluar su calidad [4].

[5] presenta dos modelos lineales predictivos para el consumo de agua potable en el sector residencial. Estos modelos son útiles para proyectar y determinar las necesidades de agua de una población. El estudio clasificó las variables que influyen en el consumo de agua potable en cuatro grupos: factores sociodemográficos, socioeconómicos, de gestión y calidad del agua, y climáticos. De las 19 variables examinadas, solo dos, la calidad del agua potable y la demografía, tuvieron un efecto notable en el consumo de agua potable cada semestre. Por otro lado, las variables climáticas, como la humedad máxima del aire y la temperatura máxima, mostraron una significancia estadística superior a las demás variables del estudio en relación con el consumo mensual de agua potable.

En Kuwait y Egipto también se realizó un estudio aplicando el aprendizaje automático y las series temporales para la predicción de la demanda de agua utilizando datos de consumo diario de agua, crecimiento poblacional y tipo de día (laboral o no). Este estudio dio como resultado que el algoritmo SVR (servicio de inteligencia exterior) superó al modelo ARIMA (modelo autorregresivo integrado de promedio móvil; acrónimo del inglés *autoregressive integrated moving average*) en precisión y eficiencia, según las métricas RMSE (error de raíz cuadrada media) y MAPE (error de porcentaje medio absoluto) [6].

El objetivo de la presente investigación fue evaluar la precisión de modelos de *machine learning* para predecir la demanda del agua y así asegurar el suministro necesario en el área metropolitana de Panamá.

### 1.2 Delimitación

Este proyecto se enfocó específicamente en la implementación de nuevas tecnologías para la gestión del agua en Panamá Metropolitana, considerando la monitorización de la cantidad del agua que consumen las áreas a estudiar.

### 1.3 Tipo de Investigación

El tipo de investigación de este proyecto es experimental, ya que el propósito de este estudio es analizar el efecto que producen las variables independientes, tales como son: la cantidad de personas que habitan en determinado sector, entre otras, sobre la variable dependiente, la demanda de agua por sectores. Adicionalmente, se realizó una experimentación de los modelos de aprendizaje supervisado para la realización de esta tarea.

La investigación considera como hipótesis que los modelos de aprendizaje automático o *machine learning* pueden ser capaces de predecir con precisión las demandas adaptándose a los cambios en las variables en estudio con el tiempo, permitiendo una planificación y gestión del agua más proactiva y eficaz.

Las variables del estudio son las siguientes:

Dependiente: demanda del agua mensual por sectores medido en millar de galones ( $y$ )

Independientes: total de clientes del IDAAN que habitan Panamá Metropolitana ( $x_1$ )

Intervinientes: ingreso mensual de los habitantes del sector, sensación térmica, temperaturas ambientales, daños en las tuberías, y gobiernos locales

## 2. Metodología

Para la ejecución de esta investigación se utilizó datos del Instituto de Acueductos y Alcantarillado de Panamá (IDAAN) extraídos de sus reportes anuales desde el año 2018 hasta el 2023. Tomando los datos residenciales mensuales, tanto como el número de clientes por mes, año y cantidad de consumo facturado en millar de galones.

Se tomó como población de estudio a los clientes que utilizan el servicio de agua potable brindado por el IDAAN en la República de Panamá. En cuanto a la muestra, son los clientes que habitan en Panamá Metropolitana.

Las herramientas utilizadas para el preprocesamiento de los datos fue Microsoft Excel, y se utilizó Jupyter Notebook (ipynb) con el lenguaje de programación Python para el análisis de los datos, visualización y evaluaciones de los modelos de aprendizaje automático supervisados.

El procesamiento de los datos se realizó de acuerdo con los siguientes pasos:

- Extracción de datos de los clientes residenciales de Panamá Metropolitana de los reportes y bases de datos del IDAAN (tabla 1) [7].

**Tabla 1.** Muestra de los datos de clientes residenciales recolectados

Mes	Año	Número de clientes	Total de consumo (millar de galones)
1	2023	305537	3846864
2	2023	305176	3871145
3	2023	305375	3799654
4	2023	305562	3783006

- Análisis exploratorio de los datos con Python incluyendo la visualización de los datos mediante una serie temporal para el número de clientes y el total de consumo. Adicionalmente se realizó un análisis estadístico de los datos, este paso se realizó con el fin encontrar patrones, tendencias y relaciones en los datos para escoger los modelos de aprendizajes automático supervisado que se ajustaran mejor a las necesidades.
- Eliminación de los valores atípicos, utilizando el método de rango Inter cuartil (IQR), donde IQR es el rango entre el primer (Q1) y el tercer cuartil (Q3) como se observa en la ecuación 1. Si el dato “x” se encuentra dentro del rango mostrado en la ecuación 2 se considera un valor atípico.

$$IQR = Q3 - Q1 \quad (1)$$

$$Q1 - 1.5 IQR < x < Q3 + 1.5 IQR \quad (2)$$

- Visualización de las correlaciones entre las variables Mes, Año, Total de clientes y Total de consumo utilizando la librería de Python, Pandas, con un mapa de calor. Teniendo en cuenta que mientras más cercado a 1 o -1 mayor correlación tendrán las variables con respecto a otra.
- Selección de los modelos de aprendizaje supervisado a utilizar.

### 2.1 Modelo de regresión lineal

Este algoritmo se utiliza para modelar datos que presentan una dependencia lineal entre sí y permite predecir el valor de una variable a partir de las variables independientes. Este modelo se describe en la ecuación 3.

$$\hat{y} = \beta_0 + \beta_1 x \dots + \beta_i x \quad (3)$$

Donde  $\hat{y}$  es el valor predicho,  $\beta_0$  es el intercepto con el eje y  $\beta_1$  es la pendiente o el incremento de la variable dependiente con respecto a las variables independientes [8].

## 2.2 Modelo de regresión Ridge

La regresión Ridge es una extensión del método de mínimos cuadrados ordinarios (OLS) utilizado en la regresión lineal, tal como se observa en la ecuación 4, pero es un algoritmo de regresión más robusto y confiable, gracias a la introducción de un término de regularización L2. Este término se añade a la suma del error cuadrático (SSE) en el método OLS, lo que permite controlar el equilibrio entre la varianza y el sesgo, esto se observa en la ecuación 5. La inclusión de la regularización ayuda a prevenir el sobreajuste al reducir la complejidad del modelo. Esto se logra encogiendo los coeficientes de regresión hacia cero, lo que se conoce como pérdida de insesgados.

$$RSS = \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij})^2 \quad (4)$$

Donde  $y_i$  representa los valores observados,  $\beta_0$  es la intersección,  $\beta_j$  representa los coeficientes de regresión,  $x_{ij}$  son las variables predictoras,  $n$  es número total de observaciones y  $p$  es el número total de variables independientes.

$$\sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda \sum_{j=1}^p \beta_j^2 \quad (5)$$

Donde  $y_i$  representa los valores observados,  $\beta_0$  es la intersección,  $\beta_j$  representa los coeficientes de regresión,  $x_{ij}$  son las variables predictoras,  $\lambda$  es el parámetro de ajuste que controla la fuerza de la contracción [8].

## 2.3 Modelo de regresión por vectores de soporte (SVR)

El modelo de SVR mapea los datos de entrenamiento en el espacio de características de alta 1-dimensión, donde este formula un hiperplano optimizado que representa la relación no lineal entre las variables independientes y las variables dependientes (ecuación 6).

$$f(x) = W^T \phi(x) + b \quad (6)$$

Donde  $(f(x))$  representa los valores de pronóstico,  $(W)$  es el factor de peso 1-dimensional,  $(b)$  es el factor ajustable, y  $(\phi(x))$  es la función de mapeo que mapea  $(X_i)$  en el espacio de características de alta 1-dimensión [9].

## 2.4 Comparación de los algoritmos

Después desarrollar los códigos en Python y utilizando la librería *Scikit Learn* para cada uno de los modelos, destacando que se determinó que el conjunto de entrenamiento sería el 80% de los datos totales y el 20% sería el conjunto de prueba, se procedió a comparar las precisiones de los algoritmos para predecir el consumo de agua potable mensual con el coeficiente de determinación  $R^2$ ,  $R^2$  ajustado y la raíz del error cuadrático medio. Esto se observa en la ecuación 7, ecuación 8 y ecuación 9, respectivamente [10].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

Donde  $y_i$  son los valores reales y  $\hat{y}_i$  son los valores predichos por el modelo.

$$R^2_{\text{ajustado}} = 1 - \frac{(1-R^2) \cdot (n-1)}{n-k-1} \quad (8)$$

Donde  $R^2$  es el coeficiente de determinación no ajustado,  $n$  es el número total de observaciones y  $k$  es el número de variables independientes en el modelo.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

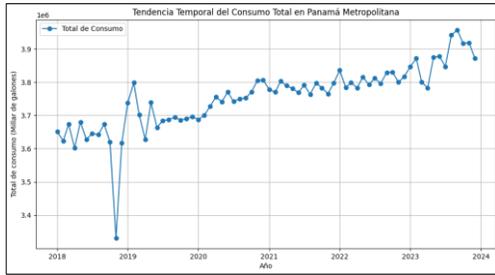
Donde RMSE es la raíz del error cuadrático medio,  $n$  es el tamaño de muestra,  $y_i$  son los valores reales y  $\hat{y}_i$  son los valores predichos por el modelo.

Después de seleccionar el modelo de regresión con el  $R^2$  ajustado más cercano a 1 y la menor magnitud de RMSE, se realizó proyecciones de consumo de agua en el área metropolitana de Panamá para los próximos cinco años (2024-2028). Además de obtener la ecuación que represente los datos.

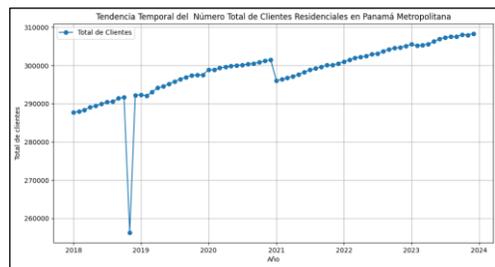
## 3. Resultados y discusión

A partir de los procedimientos realizados se obtuvieron los siguientes resultados:

En la figura 1 y figura 2 se observa la tendencia temporal de los datos de consumo total y total de clientes respectivamente al pasar de los años desde el 2018 hasta el 2023. En ellos se puede observar que para ambas variables hay un incremento a medida que el tiempo pasa, sin embargo, se observa que en noviembre del 2018 se encuentra un valor atípico que presenta una gran diferencia en comparación con los otros datos, para esto se utilizó el método IQR para suprimir su efecto al momento del entrenamiento.



**Figura 1.** Tendencia temporal del consumo del agua potable en Panamá Metropolitana.

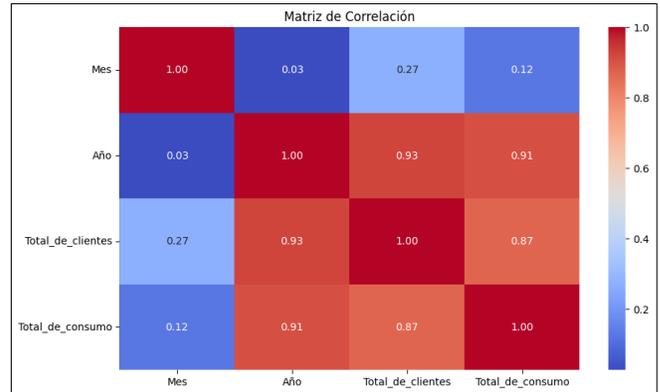


**Figura 2.** Tendencia temporal del número de clientes en Panamá Metropolitana.

Se pudo visualizar una serie temporal para el número de clientes y el total del consumo de agua potable desde enero de 2018 hasta diciembre de 2023. En el cual se obtuvo la información de que hubo un aumento general en el número de clientes a lo largo de los años con fluctuaciones mensuales en el consumo de agua.

También se generó un mapa de calor para visualizar las correlaciones entre las variables. Se puede notar una alta correlación positiva entre el número de clientes y el consumo de agua, indicando que a medida que aumenta el número de clientes también lo hace el consumo de agua esto fue mediante la matriz de correlación entre las variables estudio.

Las correlaciones entre las variables que se observa en la figura 3 muestra que el mes tiene poca correlación con las variables en comparación con las demás variables en estudio, este se encuentra entre un rango de 0.03 (año), 0.12 (total de consumo) y 0.27 (total de clientes), mientras que la variable “año” tiene la mayor correlación con el total de clientes y total de consumo, pero, esta no se tomará en cuenta porque se considerarán como variable categórica al igual que la variable de mes, por lo tanto no se incluirá en el entrenamiento del modelo de regresión.



**Figura 3.** Matriz de correlación entre las variables de estudio.

Además, se puede destacar que todas las variables presentan una correlación positiva, es decir, todas incrementan a medida que las otras lo hacen.

Se utilizaron tres modelos de aprendizaje automático para predecir el consumo mensual de agua potable. La tabla 2 presenta estos resultados después de entrenar los modelos midiéndolo con la métrica del  $R^2$  ajustado, donde la regresión lineal puede explicar el 60.36% de la variabilidad de los datos, la regresión Ridge, al igual que la regresión lineal, puede explicar el 60.36%, y el resultado más alto es el modelo SVR con un 61.78%. Esto se puede comprobar con el RMSE, donde muestra que el modelo con el menor error es el SVR.

**Tabla 2.** Resultados de los modelos de regresión entrenados

Modelo	$R^2$	$R^2$ Ajustado	RMSE
Regresión lineal	0.6319	0.6036	46598.84
Regresión Ridge	0.6319	0.6036	46598.84
SVR	0.6451	0.6178	45758.24

Lo mostrado en la tabla 2 también se puede apreciar en la figura 4, figura 5 y figura 6 donde se observa que los datos se aproximan a una distribución una lineal diagonal que parte de valor 0 en el eje x y eje y. Es importante mencionar que los modelos pueden ser considerado buenos para predecir, pero no son exactamente precisos, ya que se encuentra bajo del rango aceptable de 0.85 y 0.90.

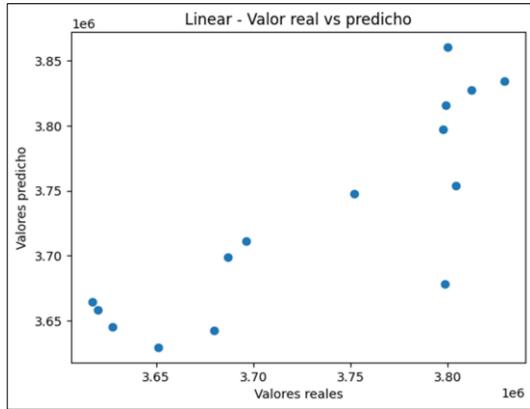


Figura 4. Gráfico de los Valores reales vs valores predicho con la regresión lineal.

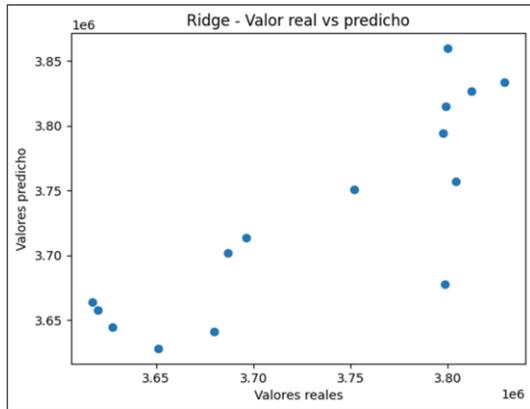


Figura 5. Gráfico de los Valores reales vs valores predicho con la regresión Ridge.

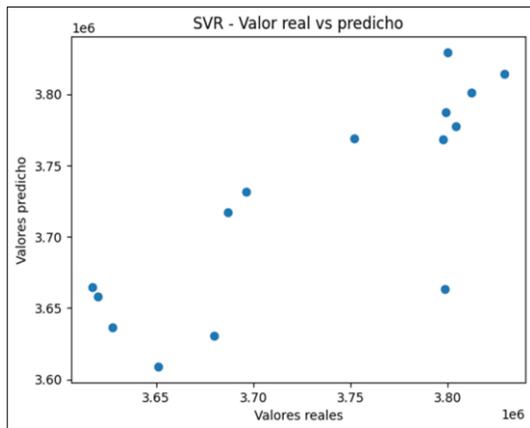


Figura 6. Gráfico de los valores reales vs valores predicho con SVR.

La figura 7 muestra las proyecciones sugieren un incremento continuo en el consumo de agua que va alineado con el crecimiento proyectado en el número de clientes residenciales en el área de Panamá metropolitana.

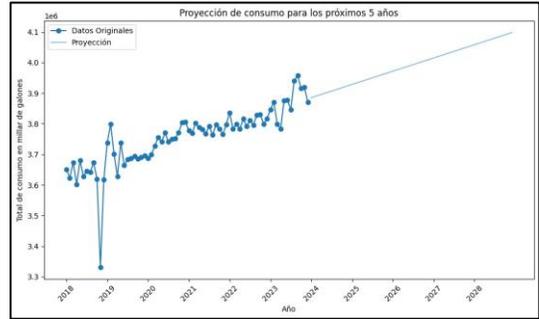


Figura 7. Proyección del consumo del agua en los próximos 5 años.

El análisis y la proyección realizada indican que el consumo de agua potable en el área metropolitana de Panamá seguirá aumentando directamente proporcional a 12.7607 millares de galones de agua potable por mes, esto se también se puede observar en la ecuación de regresión mostrado en la ecuación 9.

$$y = 12.7607x_1 - 58005.62 \quad (9)$$

Donde  $y$  son los valores predichos del consumo de agua por milla de galones y  $x_1$  son la cantidad de clientes.

Esta proyección tiene el potencial de generar conocimientos valiosos y prácticas innovadoras que pueden ser aplicadas tanto a nivel local como global, avanzando el campo científico en la gestión de recursos hídricos a través de la tecnología del aprendizaje automático.

#### 4. Conclusiones

Este proyecto demuestra la utilidad de las técnicas de *machine learning* para predecir el consumo de agua potable. Aunque con la presencia de diferentes tipos de limitaciones, como la falta y las irregularidades en la base de datos del IDAAN, que afectan a la precisión de los modelos, los resultados proporcionan una base sólida para futuras investigaciones y busca crear conciencia para la aplicación tanto de políticas como de prácticas proactivas para garantizar un suministro sostenible de agua para los próximos años y futuras generaciones.

A través de los resultados, se determinó que el modelo con mayor precisión para realizar predicciones, con respecto a las variables seleccionadas en el estudio, el coeficiente de determinación  $R^2$  ajustado y RSME, es la regresión SVR, seguido de la regresión lineal y la regresión Ridge.

Con la proyección realizada mediante el modelo de regresión SVR, se observó un incremento continuo en el consumo de agua potable en los próximos 5 años, con un comportamiento lineal alcanzando aproximadamente 4.6 millones de galones en 2028. Este hallazgo plantea la urgencia de considerar estrategias efectivas de gestión y optimización del recurso hídrico para satisfacer la creciente demanda en los próximos años.

Se considera necesario que en futuros trabajos se integren al entrenamiento de los modelos otras variables sociales, económicas y ambientales que afectan el consumo de agua, permitiendo una mayor precisión en las predicciones, así como la realización de un estudio holístico de las diferentes regiones que conforman la República de Panamá.

## AGRADECIMIENTOS

A Juan Franco y a María Gabriela Castellón por su apoyo a este proyecto.

## CONFLICTO DE INTERESES

Los autores declaran no tener algún conflicto de interés.

## REFERENCIAS

- [1] R. Chandiramani, «Casi un cuarto de los hogares en Panamá no recibe agua las 24 horas», *La Prensa Panamá*, 19 de septiembre de 2023. [En línea]. Disponible en: <https://www.prensa.com/economia/casi-un-cuarto-de-los-hogares-en-panama-no-recibe-agua-las-24-horas/>
- [2] S. Khullar and N. Singh, “Machine learning techniques in river water quality modelling: a research travelogue,” *Water Supply*, vol. 21, no. 1, pp. 1–13, Oct. 2020, doi: 10.2166/ws.2020.277.
- [3] E. K. Nti, S. J. Cobbina, E. E. Attafuah, E. Opoku, and M. A. Gyan, “Environmental sustainability technologies in biodiversity, energy, transportation and water management using artificial intelligence: A systematic review,” *Sustainable Futures*, vol. 4, p. 100068, Jan. 2022, doi: 10.1016/j.sftr.2022.100068.
- [4] É. S. Ascenção, F. M. Marinangelo, C. F. M. Almeida, N. Kagan, and E. M. Dias, “Applications of Smart Water Management Systems: A Literature review,” *Water*, vol. 15, no. 19, p. 3492, Oct. 2023, doi: 10.3390/w15193492.
- [5] A. Arellano and D. Peña, “Modelos de regresión lineal para predecir el consumo de agua potable,” *NOVASINERGIA*, vol. 3, no. 1, pp. 27–36, jun. 2020, doi: 10.37135/ns.01.05.03.
- [6] T. Ibrahim, Y. Omar, and F. A. Maghraby, “Water demand forecasting using machine learning and time series algorithms,” *IEEE Conference Publication | IEEE Xplore*, Mar. 01, 2020. <https://ieeexplore.ieee.org/abstract/document/9167651>
- [7] Instituto de Acueductos y Alcantarillados Nacionales, “Informes estadísticos comerciales-archivos,” IDAAN, 2024. <https://www.idaan.gob.pa/category/articulos/articulo-10/estructura-y-ejecucion-presupuestaria/informes-estadisticos-comerciales/>
- [8] Q. Shuang and R. T. Zhao, “Water demand prediction using machine learning methods: a case study of the Beijing–Tianjin–Hebei region in China,” *Water*, vol. 13, no. 3, p. 310, Jan. 2021, doi: 10.3390/w13030310.
- [9] G. James, D. Witten, T. Hastie, and R. Tibshirani, “An Introduction to Statistical Learning: with Applications in R.” Springer Link, 2021. <https://link.springer.com/book/10.1007/978-1-0716-1418-1>
- [10] Y. Chen et al., “Short-term electrical load forecasting using the Support Vector Regression (SVR) model to calculate the demand response baseline for office buildings,” *Applied Energy*, vol. 195, pp. 659–670, Jun. 2017, doi: 10.1016/j.apenergy.2017.03.034.