

## Forecasting con Python, caso de estudio: visitas a las redes sociales en Ecuador con machine learning

### *Forecasting with Python, case study: visits to social networks in Ecuador with machine learning*

Fabricio Marcillo<sup>1</sup>, Rebeca Rosado<sup>2</sup>, Pedro Zambrano<sup>3</sup>, Joan Velastegui<sup>4</sup>, Graciela Morales<sup>5</sup>, Luis Lagla<sup>6</sup>, Alejandro Herrera<sup>7</sup>

<sup>1</sup> Instituto Superior Tecnológico Japón, fmarcillo@itsjapon.edu.ec, Quito, Ecuador

<sup>2</sup> Instituto Superior Tecnológico Japón, rerosadol@itsjapon.edu.ec, Quito, Ecuador

<sup>3</sup> Instituto Superior Tecnológico Japón, pczambranoa@itsjapon.edu.ec, Quito, Ecuador

<sup>4</sup> Instituto Superior Tecnológico Japón, jmvelasteguih@itsjapon.edu.ec, Quito, Ecuador

<sup>5</sup> Instituto Superior Tecnológico Japón, ggmoraless@itsjapon.edu.ec, Quito, Ecuador

<sup>6</sup> Instituto Superior Tecnológico Japón, lalaglac@itsjapon.edu.ec, Quito, Ecuador

<sup>7</sup> Instituto Superior Tecnológico Japón, amherrera@itsjapon.edu.ec, Quito, Ecuador

Autor para correspondencia: fmarcillo@itsjapon.edu.ec

**Fecha de recepción:** 2023.11.06

**Fecha de aceptación:** 2024.01.18

**Fecha de publicación:** 2024.02.20

### RESUMEN

En este artículo, se enfatiza la importancia del respeto en el uso de las redes sociales en la sociedad ecuatoriana, subrayando su diversidad y la necesidad de fomentar un diálogo constructivo en lugar de la confrontación dañina en línea. Se proporciona una metodología que emplea técnicas de aprendizaje automático y modelado estadístico, como el modelo ARIMA, para predecir el tráfico web en las redes sociales de Ecuador. Además, se discuten diversas estrategias de backtesting para evaluar y mejorar la precisión del modelo a lo largo del tiempo. Los resultados indican un crecimiento significativo en el número de usuarios de redes sociales en Ecuador, con un enfoque en el modelo ARIMA como eficaz para la predicción de series temporales, aunque se sugiere la exploración de enfoques adicionales y mejoras continuas en futuras investigaciones. Este estudio contribuye a comprender mejor el impacto de las redes sociales en la sociedad ecuatoriana y proporciona una base metodológica para pronosticar el tráfico web en estas plataformas en el futuro.

**Palabras clave:** ARIMA; Backtesting; Redes sociales; Machine learning.

### ABSTRACT

This article emphasizes the importance of respect in the use of social networks in Ecuadorian society, highlighting their diversity and the need to foster constructive dialogue rather than harmful online confrontation. A methodology employing machine learning techniques and statistical modeling, such as the ARIMA model, is provided to predict web traffic on social networks in

Ecuador. In addition, various backtesting strategies are discussed to evaluate and improve the accuracy of the model over time. The results indicate significant growth in the number of social network users in Ecuador, with a focus on the ARIMA model as effective for time series prediction, although exploration of additional approaches and continued improvements are suggested in future research. This study contributes to a better understanding of the impact of social networks in Ecuadorian society and provides a methodological basis for forecasting web traffic on these platforms in the future.

**Key words:** ARIMA; Backtesting; Social networks; Machine learning.

## **INTRODUCCIÓN**

El adecuado manejo de las redes sociales en la sociedad ecuatoriana es de vital importancia, especialmente si se considera el valor fundamental del respeto a los demás. En un mundo cada vez más interconectado, las redes sociales se han convertido en una poderosa plataforma de comunicación e interacción. El respeto por los demás se convierte en un pilar esencial para mantener un entorno digital saludable y constructivo (Lupano Perugini & Castro Solano, 2023; Shen et al., 2022).

Primero, respetar a los demás en las redes sociales incluye tratar a todos con cortesía y respeto, independientemente de sus opiniones, creencias o antecedentes. La sociedad ecuatoriana, como cualquier otra sociedad, es diversa y las redes sociales pueden ser un espacio para celebrar esta diversidad en lugar de fomentar la división y el odio (Giuntini et al., 2021; Sampedro Guamán et al., 2021). Además, una buena gestión de las redes sociales promueve el diálogo constructivo en lugar de la confrontación dañina. La sociedad ecuatoriana se beneficia de la oportunidad de discutir respetuosamente temas de importancia nacional y local, fomentando un ambiente de entendimiento y cooperación (Figueroa-Benítez et al., 2021).

Asimismo, respetar a los demás en las redes sociales ayuda a proteger la privacidad y la seguridad personal. Es importante recordar que detrás de cada perfil hay una persona real con intereses y sentimientos. Usar la información de manera responsable y no difundir contenidos nocivos son principios fundamentales en una sociedad que valora la dignidad humana (Acevedo-Argüello et al., 2020; Wei et al., 2020).

De esta manera, un adecuado manejo de las redes sociales en la sociedad ecuatoriana, basado en el respeto por los demás, es fundamental para fomentar un entorno digital que fomente la comunicación positiva, el entendimiento y la convivencia mutua en armonía. El uso responsable de estas plataformas contribuye a construir una sociedad más inclusiva y respetuosa (Luo et al., 2022; Tejedor et al., 2021).

Las redes sociales en Ecuador, a mayo de 2023, alcanzaron 15,7 millones de cuentas en Meta (Facebook + Instagram), 14 millones de cuentas en Facebook, 11,91 millones de cuentas en TikTok, 7 millones de cuentas en Instagram, 6,2 millones de cuentas en Spotify, 3,9 millones de cuentas en LinkedIn, 3,5 millones de cuentas en Twitter, 0,7 millones de cuentas en Messenger, 0,5 millones de cuentas en Audience Network (Informe Estado Digital Ecuador 2023 - Mentinno - Acompañamiento directivo y analítica para negocios, 2023).

Una serie temporal es una serie de datos clasificados en orden cronológico, separados a intervalos iguales o desiguales. El proceso de pronóstico implica predecir el valor futuro de una serie de tiempo, ya sea modelando la serie basándose únicamente en su comportamiento pasado (autorregresivo) o utilizando otras variables externas (Nguyen et al., 2022; Yuliansyah et al., 2020).

Este artículo presenta un ejemplo del uso de aprendizaje automático y modelado estadístico (ARIMA) para predecir el número de visitas diarias que reciben las redes sociales. Para ello utilizamos skforecast, una sencilla biblioteca de Python que permite, entre otras cosas, adaptar cualquier motor de regresión scikit-learn a problemas de previsión (Ashok et al., 2023; Maqsood et al., 2022; Prakhar et al., 2022).

## **MATERIALES Y MÉTODOS**

La data útil provee un historial diario de acceso a redes sociales disponible a partir del 01 de julio de 2022. El objetivo es crear un modelo de previsión capaz de predecir cuánto tráfico web tendrán las redes sociales en 7 días. En concreto, el usuario quiere poder ejecutar el modelo todos los lunes y recibir previsiones de tráfico diarias hasta el lunes siguiente.

Para poder evaluar de forma robusta el rendimiento del modelo según su uso previsto, no se debe limitarse a predecir solo los últimos 7 días de la serie temporal, sino que se debe simular todo el proceso. El backtesting es un tipo especial de validación cruzada que se aplica a los períodos anteriores y se puede utilizar con diferentes estrategias.

El backtesting con reentrenamiento, o "refit" en inglés, es una técnica de evaluación de modelos de aprendizaje automático que implica entrenar un modelo inicial con un conjunto de datos, evaluar su rendimiento en un conjunto de prueba y luego reentrenar el modelo combinando tanto los datos de entrenamiento como los de prueba. Este enfoque se utiliza para adaptar y mejorar continuamente el modelo a medida que se dispone de nuevos datos, lo que es especialmente útil en situaciones en las que los datos cambian con el tiempo, como en los mercados financieros. El backtesting con reentrenamiento ayuda a asegurarse de que el modelo sea capaz de adaptarse a las condiciones cambiantes y mantener su precisión predictiva a lo largo del tiempo.

El proceso de reentrenamiento implica actualizar el modelo con datos más recientes, lo que puede ayudar a prevenir la obsolescencia del modelo y garantizar que siga siendo relevante y efectivo en un entorno en constante evolución. Sin embargo, es esencial equilibrar el reentrenamiento con la necesidad de evitar el sobreajuste, ya que un reentrenamiento excesivo puede hacer que el modelo se ajuste demasiado a los datos específicos y pierda su capacidad de generalización.

El backtesting con reentrenamiento y tamaño de entrenamiento constante, conocido como "rolling origin," es una técnica de evaluación utilizada en el desarrollo y validación de modelos de aprendizaje automático. En este enfoque, un modelo se entrena inicialmente con un conjunto de datos históricos y se evalúa con un conjunto de prueba. Sin embargo, a diferencia del enfoque tradicional de backtesting en el que se utilizan conjuntos de entrenamiento y prueba fijos, el rolling origin implica deslizar una ventana temporal sobre los datos, manteniendo un tamaño de entrenamiento constante a medida que se avanzan en el tiempo.

El rolling origin es valioso en situaciones en las que los datos cambian con el tiempo o siguen una tendencia temporal. Permite evaluar la capacidad predictiva del modelo a medida que se avanza en el tiempo y se presentan nuevos datos. Esta técnica es especialmente útil en campos como la

predicción financiera, donde las condiciones del mercado evolucionan constantemente. Al utilizar un tamaño de entrenamiento constante, el rolling origin refleja con mayor precisión la capacidad del modelo para adaptarse a condiciones cambiantes, lo que resulta en evaluaciones más realistas y prácticas de su rendimiento a lo largo del tiempo.

El backtesting con reentrenamiento intermitente es una estrategia de evaluación utilizada en el campo del aprendizaje automático y la modelización predictiva. En este enfoque, en lugar de realizar reentrenamientos continuos, se programa un reentrenamiento periódico del modelo cada "n" periodos de tiempo predeterminados. Durante cada ciclo de reentrenamiento, el modelo se actualiza con datos más recientes y se evalúa su rendimiento en un conjunto de prueba, lo que permite adaptar el modelo a cambios en los datos y en las condiciones del entorno en intervalos regulares.

Esta técnica es útil en situaciones en las que los datos pueden no cambiar de manera constante, pero se espera que el modelo se ajuste a las tendencias a lo largo del tiempo. Al reentrenar el modelo en intervalos específicos, se equilibra la necesidad de adaptación continua con la estabilidad del modelo, lo que puede resultar en una mejor capacidad predictiva a medida que se incorporan nuevos datos. El backtesting con reentrenamiento intermitente es especialmente valioso en escenarios como la predicción de ventas a largo plazo o la gestión de carteras financieras, donde los patrones pueden cambiar gradualmente con el tiempo y es importante mantener un equilibrio entre la adaptación y la estabilidad del modelo.

El backtesting sin reentrenamiento es una técnica utilizada en la evaluación de modelos de aprendizaje automático y estadísticos en la que un modelo se entrena una sola vez en un conjunto de datos inicial y luego se evalúa su rendimiento en un conjunto de prueba sin someterlo a reentrenamiento continuo. A diferencia de otras estrategias, en este enfoque, el modelo se considera estático una vez que ha sido entrenado inicialmente y se evalúa únicamente en función de su capacidad para generalizar y hacer predicciones precisas en datos futuros sin modificaciones.

Esta técnica es apropiada en situaciones donde se desea medir la capacidad de un modelo para mantener su rendimiento sin ajustes o cambios. Sin embargo, es importante destacar que en

entornos en los que los datos cambian con el tiempo o las condiciones evolucionan, el backtesting sin reentrenamiento puede tener limitaciones, ya que el modelo puede volverse menos preciso con el tiempo si no se ajusta a nuevas tendencias o patrones emergentes. Por lo tanto, la elección de utilizar esta estrategia depende de la estabilidad de los datos y la necesidad de adaptación continua del modelo.

La elección del método de validación más apropiado dependerá de la estrategia adoptada para la implementación en producción, particularmente si se planea reentrenar periódicamente el modelo antes de ejecutar las predicciones. En cualquier caso, es esencial evitar la inclusión de los datos de prueba en el proceso de búsqueda, independientemente de la estrategia seleccionada, para prevenir problemas de overfitting.

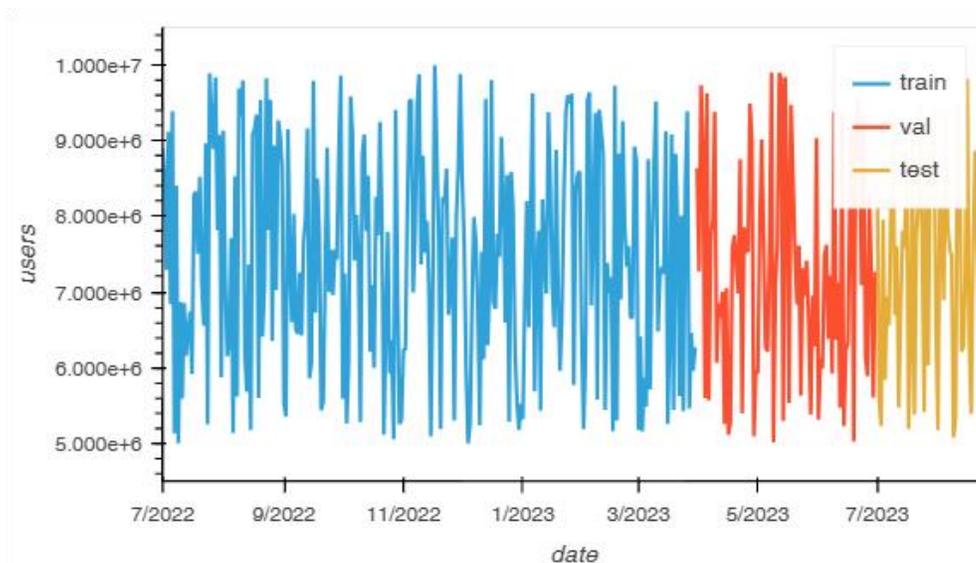
## **RESULTADOS Y DISCUSIÓN**

Cuando se trabaja en la creación de un modelo de forecasting, es fundamental contar con una representación adecuada de la serie temporal en estudio. Esta representación implica capturar la estructura subyacente de los datos a lo largo del tiempo, lo que, a su vez, permite identificar patrones significativos (véase Figura 1).

Uno de los patrones más comunes que se busca en un análisis de series temporales es la tendencia, que se refiere a una dirección general en la evolución de los datos, ya sea crecimiento, declive o una estabilidad a largo plazo. La capacidad de identificar tendencias es esencial para tomar decisiones informadas, como planificar estrategias de crecimiento corporativo o ajustar políticas cambiarias.

Además de la tendencia, la representación adecuada de la serie temporal también permite detectar patrones de estacionalidad, que se refieren a fluctuaciones recurrentes que siguen un ciclo regular a lo largo del tiempo (véase Figura 1). Estos patrones estacionales son críticos para la predicción precisa, especialmente en áreas como los negocios minoristas en redes sociales, donde las ventas pueden aumentar estacionalmente durante las vacaciones. En resumen, la representación de los valores de la serie temporal es un paso crucial en la creación de modelos de forecasting, ya que

permite identificar y comprender los patrones de tendencia y estacionalidad que son esenciales para la toma de decisiones y la planificación estratégica en una variedad de campos.



**Figura 1.** Visitas diarias de redes sociales

La estacionalidad en análisis de series temporales se refiere a patrones recurrentes que se repiten a lo largo del tiempo, y puede manifestarse en diferentes escalas. La estacionalidad anual, por ejemplo, es un patrón que se repite cada año (véase Figura 2), como las variaciones en las ventas al por menor que se observan en períodos festivos. A nivel mensual (véase Figura 3), la estacionalidad puede manifestarse en ciclos regulares dentro de cada mes (véase Figura 4), como los patrones climáticos estacionales o la demanda de ciertos productos en un mes específico del año.

Por otro lado, la estacionalidad semanal es aún más específica, con patrones que se repiten cada semana, como la afluencia de clientes en un restaurante que tiende a aumentar los fines de semana. Estos patrones estacionales son críticos en el forecasting, ya que permiten anticipar y ajustar las operaciones o las estrategias comerciales según las variaciones predecibles en

diferentes escalas temporales, optimizando así la planificación y la toma de decisiones.

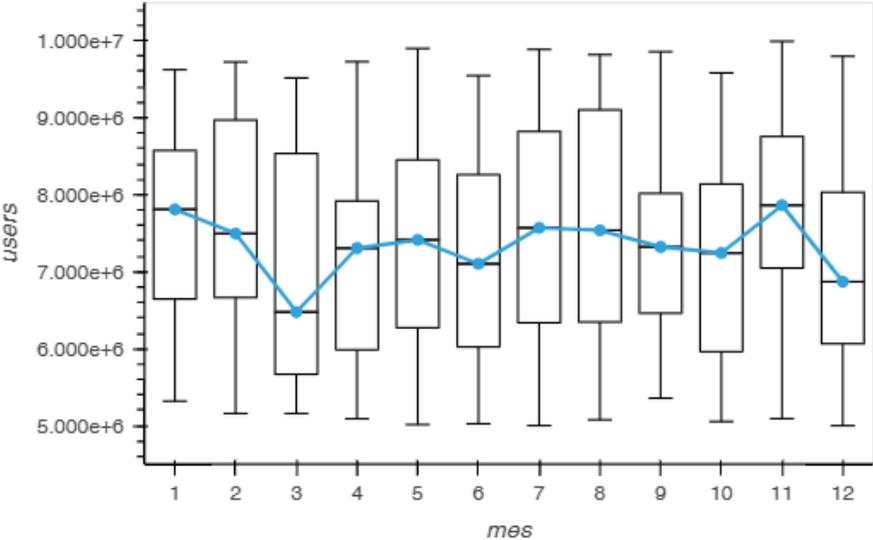


Figura 2. Distribución de visitas por mes

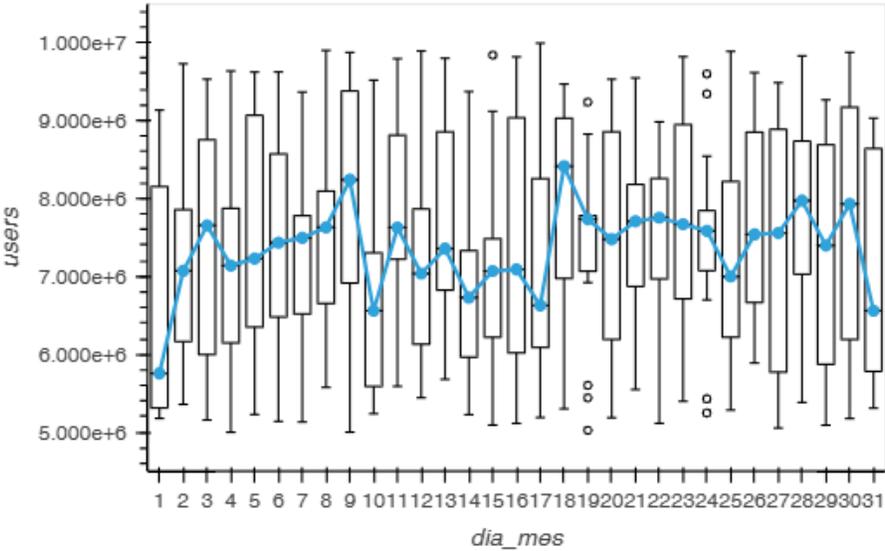
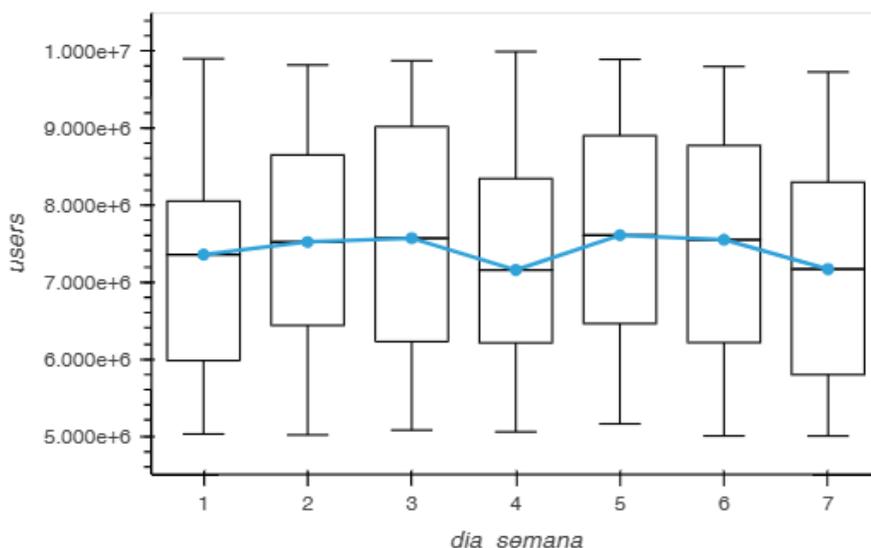


Figura 3. Distribución de visitas por días del mes



**Figura 4.** Distribución de visitas por día de la semana

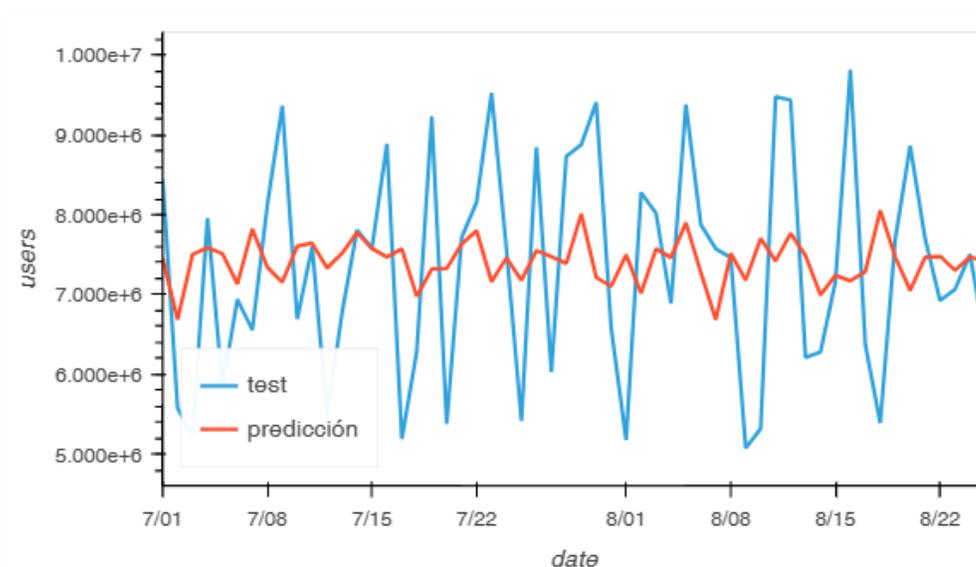
En el proceso de construcción y entrenamiento del Modelo Autorregresivo Recursivo (ForecasterAutoreg), se parte de un modelo de regresión lineal potenciado por la penalización Ridge, una técnica que ayuda a evitar el sobreajuste del modelo (véase Figura 5). Este enfoque incorpora una ventana temporal de 2 semanas, lo que significa que, en cada etapa de predicción, se utilizan como predictores los datos de tráfico registrados en los 14 días previos, aprovechando así la información histórica para informar las proyecciones futuras.

Además, es esencial destacar que, en el contexto de modelos Ridge, es necesario que los predictores estén estandarizados, lo cual garantiza que todas las variables de entrada estén en la misma escala, lo que es crucial para el funcionamiento eficiente de la regresión lineal y la penalización Ridge. Para llevar a cabo esta estandarización, se implementa un StandardScaler mediante el argumento transformer\_y, lo que permite que el modelo se ajuste de manera óptima a los datos, mejorando así su capacidad predictiva y su capacidad de generalización en aplicaciones de pronóstico.

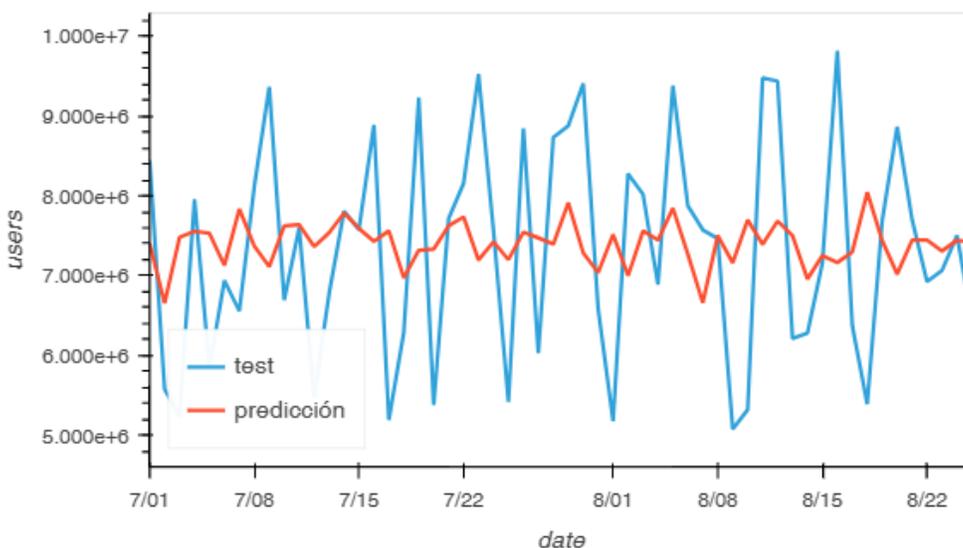
Un modelo SARIMAX (Seasonal Autoregressive Integrated Moving-Average with Exogenous Regressors) se erige como una extensión potente del modelo ARIMA, capaz de capturar tanto la estacionalidad inherente en las series temporales como la influencia de variables exógenas en los datos (véase Figura 6). Los modelos SARIMAX ocupan un lugar destacado en el arsenal de

herramientas de forecasting, ya que combinan la capacidad de modelar tendencias, estacionalidades y comportamientos de datos con la flexibilidad de incorporar factores externos que pueden afectar las predicciones.

Skforecast, en su implementación, aprovecha la funcionalidad del modelo ARIMA proporcionado por la librería pmdarima en combinación con el ForecasterSarimax. Asimismo, ofrece utilidades adicionales como las funciones `backtesting_sarimax()` y `grid_search_sarimax()` en su módulo `model_selection_sarimax`, lo que permite llevar a cabo tanto la validación rigurosa de los modelos SARIMAX como su optimización, facilitando la obtención de pronósticos altamente precisos y adecuados a una amplia gama de aplicaciones prácticas.



**Figura 5.** Predicción (Autoreg-Ridge) vs vistas reales



**Figura 6.** Predicción ARIMA vs visitas reales

El forecasting con variables exógenas expande la capacidad predictiva al incorporar información adicional que puede influir en el comportamiento de la variable objetivo. A diferencia de los modelos que se basan únicamente en lags de la variable objetivo, esta estrategia permite aprovechar la disponibilidad de datos relacionados, cuyos valores futuros son conocidos. Esto resulta especialmente relevante en situaciones donde factores como días festivos, el mes del año, el día de la semana o incluso la hora del día pueden tener un impacto significativo en las predicciones.

Por ejemplo (véase Figura 7), al observar el análisis gráfico que muestra una disminución de las visitas a las redes sociales los fines de semana, se puede emplear el día de la semana como variable exógena para mejorar la precisión del modelo. La inclusión de estas variables externas en el proceso de forecasting permite explorar y cuantificar cómo afectan a las predicciones, lo que resulta en modelos más robustos y adecuados para capturar la complejidad de las relaciones en los datos.

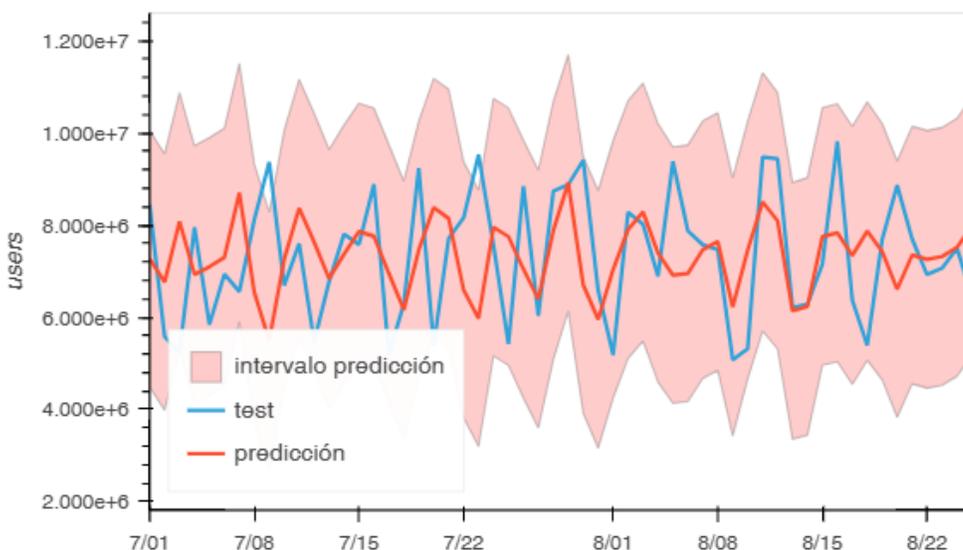


Figura 7. Predicción ARIMA vs visitas reales

## CONCLUSIONES

El notable crecimiento porcentual de usuarios en las redes sociales en Ecuador durante el período de septiembre de 2022 a mayo de 2023 refleja una tendencia significativa en la adopción y el uso de plataformas digitales en el país. Estos impresionantes incrementos en la base de usuarios muestran la importancia continua de las redes sociales en la vida de las personas, así como su influencia en diversos aspectos de la sociedad ecuatoriana. Facebook 19,99%, Instagram 13,31%, TikTok 32,05%, Spotify 10,71%, LinkedIn 11,43% y Twitter 84,21%. han experimentado un aumento considerable en su número de usuarios, destacando el interés y la participación de la población en estas plataformas. Este fenómeno subraya la creciente relevancia de las redes sociales como canales de comunicación, entretenimiento y networking en Ecuador, lo que tiene importantes implicaciones en áreas como el marketing, la comunicación empresarial y la influencia digital.

La concentración de usuarios mayores de edad en Ecuador, con un total de 14'590.000 personas registradas hasta mayo de 2023, ofrece una visión reveladora de la distribución demográfica en el país. Estos usuarios están repartidos en diversas ciudades, con Guayaquil y Quito liderando la lista con el 19,25% y el 14,23%, respectivamente. La presencia significativa de usuarios en ciudades como Cuenca, Santo Domingo, Machala, Manta, Portoviejo, Ambato, Durán y Riobamba demuestra la

penetración de la red social meta en todo el territorio ecuatoriano. Este vasto alcance refleja el impacto de las redes sociales como plataformas de comunicación y participación en la vida cotidiana de las personas en Ecuador y destaca su influencia en una amplia variedad de ámbitos, desde la política hasta el comercio y la cultura.

En el marco de nuestro estudio, es evidente que el modelo ARIMA sobresale al alcanzar un puntaje impresionante en el backtesting, mostrando un valor de 1'102.425,75 frente a 1'139.257,36. Esto destaca la eficacia de ARIMA en la predicción de series temporales y su capacidad para capturar patrones significativos en los datos. No obstante, siempre existe margen para la mejora, y en este contexto, se podrían explorar enfoques adicionales para enriquecer aún más el modelo. Una posible mejora podría ser la incorporación de información sobre si un día es festivo a nivel nacional como predictor, lo que podría ayudar a capturar las variaciones en el comportamiento durante las festividades. Además, la exploración de modelos autorregresivos no lineales, como Random Forest o Gradient Boosting, podría ser beneficioso, ya que estos modelos tienen la capacidad de manejar relaciones más complejas en los datos. Otra opción interesante es el uso de modelos de pronóstico directo de múltiples pasos que proporcionen predicciones a largo plazo en lugar de iteraciones secuenciales, lo que podría adaptarse mejor a ciertas situaciones de series temporales.

Además, aunque ARIMA ha demostrado ser un modelo sólido en este contexto, siempre es prudente explorar alternativas y considerar la incorporación de predictores adicionales para abordar la complejidad de los datos. La elección del modelo óptimo dependerá en última instancia de la naturaleza de los datos y de los objetivos específicos del pronóstico, y la búsqueda de mejoras continuas es esencial para mantener la precisión en el análisis de series temporales.

## **REFERENCIAS**

- Acevedo-Argüello, C., Zabala-Vargas, S., Rojas-Mesa, J., & Guayán-Perdomo, O. (2020). Análisis de Redes Sociales como estrategia para estudiar los Sistemas de Innovación. Revisión sistemática de la literatura. *Revista Interamericana de Investigación Educación y Pedagogía RIIEP*, 13(2), 370–402. <https://doi.org/10.15332/25005421.6238>
- Ashok, K., Rajalakshmi, B., Chaitanya Reddy, K. S., Priyanka Guggulla, G., & Santhosh Krishna, B. V. (2023). A Novel Women Safety Analyis and Monitoring Sysetm over Social Media

- using Machine Learning. 2023 3rd International Conference on Intelligent Technologies, CONIT 2023, 1–5. <https://doi.org/10.1109/CONIT59222.2023.10205753>
- Figueroa-Benítez, J. C., González-Quiñones, F., & Machin-Mastromatteo, J. D. (2021). Instagram como objeto de estudio en investigaciones recientes. Una revisión de literatura con enfoque en revistas científicas. *Ámbitos. Revista Internacional de Comunicación*, 53(53), 9–23. <https://doi.org/10.12795/ambitos.2021.i53.01>
- Giuntini, F. T., De Moraes, K. L., Cazzolato, M. T., De Fatima Kirchner, L., De Jesus D. Dos Reis, M., Traina, A. J. M., Campbell, A. T., & Ueyama, J. (2021). Modeling and Assessing the Temporal Behavior of Emotional and Depressive User Interactions on Social Networks. *IEEE Access*, 9, 93182–93194. <https://doi.org/10.1109/ACCESS.2021.3091801>
- Informe Estado Digital Ecuador 2023 - Mentinno - Acompañamiento directivo y analítica para negocios. (2023, 29 junio). Mentinno - Acompañamiento directivo y analítica para negocios. <https://www.mentinno.com/informe-estado-digital-ecuador-2023/>
- Luo, T., Cao, Z., Zeng, D., & Zhang, Q. (2022). A Dissemination Model Based on Psychological Theories in Complex Social Networks. *IEEE Transactions on Cognitive and Developmental Systems*, 14(2), 519–531. <https://doi.org/10.1109/TCDS.2021.3052824>
- Lupano Perugini, M. L., & Castro Solano, A. (2023). Uso pasivo de redes sociales y malestar psicológico. El rol de la comparación social. *Interdisciplinaria. Revista de Psicología y Ciencias Afines*, 40(2), 543–558. <https://doi.org/10.16888/interd.2023.40.2.31>
- Maqsood, U., Khuhawar, F. Y., Talpur, S., Jaskani, F. H., & Memon, A. A. (2022). Twitter Mining based Forecasting of Cryptocurrency using Sentimental Analysis of Tweets. 2022 Global Conference on Wireless and Optical Technologies, GCWOT 2022, 1–6. <https://doi.org/10.1109/GCWOT53057.2022.9772923>
- Nguyen, L., Yang, Z., Li, J., Pan, Z., Cao, G., & Jin, F. (2022). Forecasting People’s Needs in Hurricane Events from Social Network. *IEEE Transactions on Big Data*, 8(1), 229–240. <https://doi.org/10.1109/TBDATA.2019.2941887>
- Prakhar, K., Sountharajan, S., Suganya, E., Karthiga, M., & Sathis Kumar, B. (2022). Effective Stock Price Prediction using Time Series Forecasting. 2022 6th International Conference on Trends in Electronics and Informatics, ICOEI 2022 - Proceedings, Icoei, 1636–1640. <https://doi.org/10.1109/ICOEI53556.2022.9776830>

- Sampedro Guamán, C. R., Palma Rivera, D. P., Machuca Vivar, S. A., & Arrobo Lapo, E. V. (2021). Digital transformation of marketing in small and medium companies through social networks. *Universidad y Sociedad*, 13(3), 484–490.
- Shen, C. Y., Yang, D. N., Lee, W. C., & Chen, M. S. (2022). Activity Organization for Friend-Making Optimization in Online Social Networks. *IEEE Transactions on Knowledge and Data Engineering*, 34(1), 122–137. <https://doi.org/10.1109/TKDE.2020.2980516>
- Tejedor, S., Cervi, L., Martínez, F., & Tusa, F. (2021). Principales motivaciones en el uso de redes sociales en estudiantes de Comunicación: perspectiva comparada entre Colombia, Ecuador y España. *Journal of Iberian and Latin American Research*, 27(1), 163–182. <https://doi.org/10.1080/13260219.2021.1947353>
- Wei, X., Xu, G., Wang, H., He, Y., Han, Z., & Wang, W. (2020). Sensing Users' Emotional Intelligence in Social Networks. *IEEE Transactions on Computational Social Systems*, 7(1), 103–112. <https://doi.org/10.1109/TCSS.2019.2944687>
- Yuliansyah, H., Othman, Z. A., & Bakar, A. A. (2020). Taxonomy of link prediction for social network analysis: A review. *IEEE Access*, 8(1), 183470–183487. <https://doi.org/10.1109/ACCESS.2020.3029122>