

Demanda de electricidad en el Perú periodo 1997-2025: aplicación del modelo de series de tiempo SARIMAX

Resumen

Sebastian Ayala Beas

XIII PEEA, Centro de Formación Continua de la FIEECS, Universidad Nacional de Ingeniería, Perú.

<https://orcid.org/0000-0003-0565-9704>

Melissa Blest Cáceres

XIII PEEA, Centro de Formación Continua de la FIEECS, Universidad Nacional de Ingeniería, Perú.

<https://orcid.org/0009-0007-0305-680X>

René Cornejo Díaz

XIII PEEA, Centro de Formación Continua de la FIEECS, Universidad Nacional de Ingeniería, Perú.

<https://orcid.org/0000-0002-9427-7304>

Marly Huamán Palacios

XIII PEEA, Centro de Formación Continua de la FIEECS, Universidad Nacional de Ingeniería, Perú.

<https://orcid.org/0009-0003-9383-3609>

Cesar Santa Cruz Huaman

XIII PEEA, Centro de Formación Continua de la FIEECS, Universidad Nacional de Ingeniería, Perú.

<https://orcid.org/0009-0006-2354-9911>

En los últimos años se ha evidenciado un crecimiento sostenido del sector eléctrico, el cual ha servido de soporte al desarrollo. En este sentido, la investigación tiene como objetivo analizar y proyectar la demanda de electricidad en Perú, mediante la aplicación de la metodología Box-Jenkins, con el modelo SARIMAX (2,1,2)(1,0,1)[4] estimado, que reduce significativamente el Criterio de Información de Schwarz. De acuerdo con el pronóstico, se proyecta una tasa de crecimiento interanual promedio de 4,99 % en la demanda de electricidad durante los próximos doce trimestres. Estos hallazgos proporcionan proyecciones confiables que sirven como herramienta estratégica para mejorar la planificación y gestión del sistema y mercado eléctrico. Finalmente, esta investigación destaca la importancia de integrar variable económica clave, como el PBI, en el desarrollo de modelos de predicción energéticos.

Palabras claves: Pronóstico; Modelo SARIMAX; Series de tiempo; Demanda de electricidad y PBI

Cómo citar este artículo: Demanda de electricidad en el Perú periodo 1997-2025: aplicación del modelo de series de tiempo SARIMAX. (2025). *Economía & Gestión Chaninchaatsiq*, 3(2), pp. 103-114. <https://doi.org/10.32911/egc.2025.v3.n2.1364>

Recibido: 2025-08-05 | **Aceptado:** 2025-10-12



Electricity Demand in Peru, 1997–2025: An Application of the SARIMAX Time Series Model

In recent years, the electricity sector has exhibited sustained growth, serving as a key driver of economic development. In this context, this study aims to analyze and forecast electricity demand in Peru by applying the Box–Jenkins methodology, using an estimated SARIMAX (2,1,2)(1,0,1)[4] model, which significantly reduces the Schwarz Information Criterion. According to the forecasts, an average year-on-year growth rate of 4.99% in electricity demand is projected for the next twelve quarters. These findings provide reliable projections that serve as a strategic tool to enhance planning and management of the electricity system and market. Finally, this research highlights the importance of incorporating key economic variables, such as GDP, in the development of energy demand forecasting models.

Keywords: Forecasting, SARIMAX model, time series, electricity demand, GDP

Introducción

El crecimiento económico del Perú ha impulsado un aumento sostenido en la demanda de electricidad, consolidándola como un recurso esencial para el desarrollo industrial, comercial y residencial. Sin embargo, la volatilidad económica y los cambios en los patrones de consumo energético presentan desafíos significativos para la planificación y gestión del sistema eléctrico. Estos retos requieren herramientas de pronóstico robustas que permitan anticipar el comportamiento futuro de la demanda y respaldar decisiones estratégicas en inversión y políticas públicas.

Además, el país enfrenta importantes desafíos en el ámbito energético, reflejados en el acceso limitado a la electricidad y en la alta dependencia de

la leña y de los combustibles importados (Colina-Calvo, 2024) "ISSN": "27093689", "abstract": "Peru is in the race to eliminate poverty, inequality and environmental pollution according to the Sustainable Development Goals (SDGs. No obstante, en los últimos años se ha evidenciado un crecimiento sostenido del sector eléctrico, el cual ha servido de soporte al desarrollo del Perú (Ruiz Roldán & Mimbela Jiménez, 2021). En este contexto, la elaboración de pronósticos de la demanda de electricidad se vuelve esencial para anticipar las necesidades energéticas futuras, orientar la planificación de la infraestructura eléctrica, optimizar la asignación de recursos y contribuir al diseño de políticas públicas sostenibles que garanticen la seguridad y eficiencia del suministro energético nacional.

Para tal efecto, una de las herramientas que ofrece la econometría es el análisis de series de tiempo, el cual permite desarrollar modelos relativamente simples capaces de realizar pronósticos (Enders, 2014). De hecho, el campo de la econometría se originó principalmente con el análisis de series temporales, ya que muchos de los primeros conjuntos de datos eran datos macroeconómicos (Hansen, 2017). En este sentido, uno de los modelos más populares, y que han demostrado tener mayor capacidad de predicción frente a modelos más complejos (Levendis, 2023), son los de tipo ARIMA (acrónimo derivado del inglés *AutoRegressive Integrated Moving Average*). En particular, en esta investigación se emplea una variante de este tipo de modelos, denominado SARIMAX (Modelo ARIMA estacional con variable exógena). SARIMAX aplica un enfoque de series de tiempo con factores de influencia estacionales y exógenos, que ayuda a reducir los valores de error y mejorar la precisión general del modelo, en comparación con las técnicas basadas en el promedio móvil integrado autorregresivo (Alharbi & Csala, 2022) generation, peak load, and installed capacity.

En consecuencia, este estudio tiene como objetivo analizar y proyectar la demanda de electricidad en Perú para el periodo de mediano plazo, empleando un modelo de series de tiempo con el Producto Bruto Interno (PBI) como variable exógena. Basándose en datos históricos desde 1997 hasta 2025, se evalúa la estacionariedad de la demanda y la relevancia estadística de la inclusión del PBI para mejorar el desempeño del modelo. Este enfoque busca ofrecer una herramienta analítica sólida que contribuya al diseño de políticas energéticas eficientes, optimizando la infraestructura eléctrica y garantizando un suministro sostenible en un entorno económico en constante evolución.

Revisión de la Literatura

Lee (2025) desarrolla un modelo de pronóstico basado en SARIMAX para predecir la llegada mensual de visitantes a Singapur, integrando datos de búsqueda web de Google Trends y factores externos. Los resultados de los experimentos empíricos demuestran que el modelo SARIMAX propuesto supera a los modelos univariados tradicionales, como SARIMA, Holt-Winters y Prophet, así como a los enfoques basados en aprendizaje automático. Al pronosticar el período de 24 meses de 2023 y 2024, el modelo propuesto alcanza el Error Porcentual Absoluto Medio más bajo, del 7,32 %. De igual manera, Manigandan et al. (2021) realizan una comparación sobre la aplicación de diferentes modelos en la previsión de la producción y el consumo mensual de gas natural para Estados Unidos. Sus resultados indican la superioridad del modelo SARIMAX, frente al modelo SARIMA. Concluye que para el 2025, la producción y el consumo de gas natural de los Estados Unidos aumenten en 16% y 24% respectivamente. Por su parte, Sarpong-Streeter et al. (2021) examinan la capacidad de ARIMAX para modelar el precio la gasolina de 97 octanos en Malasia, utilizando el precio del petróleo crudo como serie temporal exógena. Los autores

concluyen que es posible modelar y pronosticar con precisión utilizando ARIMAX.

Mediante la aplicación de la metodología Box-Jenkins, Guevara Bernal & Guevara Bernal (2019) identificaron un modelo ARIMAX adecuado para representar la dinámica de la tasa de subempleo subjetivo por competencias, incorporando como variable exógena la tasa de desempleo nacional en Colombia. Los resultados indican que el modelo cumple de manera satisfactoria con los supuestos estadísticos de validez, y evidencian que la tasa de desempleo constituye un determinante significativo en la explicación del comportamiento de la tasa de subempleo subjetivo por competencias en Colombia. Del mismo modo, Amézquita Bravo (2021) en su investigación realiza un análisis comparativo de modelos de series de tiempo para pronosticar la demanda de transporte aéreo en Colombia. Sus hallazgos confirman que el modelo multivariado SARIMAX presenta un desempeño superior en las proyecciones en comparación con los modelos univariantes de series de tiempo. Señala que el PBI mejora la capacidad predictiva del modelo y reafirma la relación positiva existente entre el crecimiento económico y la actividad del sector aéreo colombiano.

En el caso de los antecedentes nacionales, no se logró identificar estudios públicamente disponibles, que apliquen modelos SARIMAX para la elaboración de pronósticos. No obstante, para el caso de los antecedentes sobre el pronóstico del consumo o producción eléctrica en el Perú, Cabrera Torres (2023), mediante la aplicación de un modelo de vectores autorregresivos (VAR), se estima que el consumo de electricidad en el cuarto trimestre de 2027 alcanzará aproximadamente 14.960 GWh en el escenario medio, 16.859,6 GWh en el escenario alto y 12.949,8 GWh en el escenario bajo. Por último, se encontró investigaciones centradas fundamentalmente en el corto plazo, con análisis enfocados en horizontes diarios (Gonzales Chávez,

2014) o el índice de producción mensual (Damián Llatas & Sandoval Santamaría, 2019).

Metodología

El modelo ARIMAX estacional (SARIMAX) identifica los patrones de series temporales dentro de la serie, capturando la covarianza lineal entre la variable objetivo y las variables exógenas. El modelo SARIMAX estándar sigue la notación ARIMAX (p,d,q) x (P,D,Q)_S, donde p es el orden autorregresivo (AR) no estacional, d es la diferenciación no estacional, q es el orden de la media móvil (MA) no estacional, P es el orden AR estacional, D es la diferenciación estacional, Q es el orden MA estacional y S es el intervalo de tiempo del patrón estacional repetitivo (Cai et al., 2019).

La aplicación de los modelos SARIMAX en el análisis y la previsión de series temporales requiere varios pasos esenciales, como asegurar la estacionariedad de las series temporales y determinar el orden de los componentes AR, MA, AR estacional y MA estacional. Este enfoque sistemático, conocido

como metodología Box-Jenkins, constituye la base para un modelado robusto de series temporales (Box et al., 2016). Este procedimiento se llevará a cabo para lograr resultados confiables.


Los datos de la demanda de electricidad están expresados en gigavatio-hora (GWH) y el producto bruto interno por tipo de gasto en millones de S/ de 2007. Las series trimestrales corresponden al periodo del segundo trimestre de 1997 al segundo trimestre de 2025, lo que da un total de 112 observaciones. Ambas variables se extrajeron de fuentes secundarias, específicamente del Banco Central de Reserva del Perú. Además, el presente estudio es de diseño no experimental, con enfoque cuantitativo y de tipo longitudinal (Hernández Sampieri & Mendoza Torres, 2018). Para el análisis estadístico de las series de tiempo se empleó el software EViews 12.

Resultados

En la Figura 1 se presenta el diagrama de dispersión entre la demanda de electricidad y el PBI. El análisis visual permite identificar una relación positiva entre ambas variables y los resultados muestran una correlación de Pearson del 0.9866. Esta alta relación entre ambas variables fue uno de los criterios considerados para estimar el modelo SARIMAX.

Figura 1

Diagrama de dispersión entre las variables



Nota: Elaborado con datos del BCRP

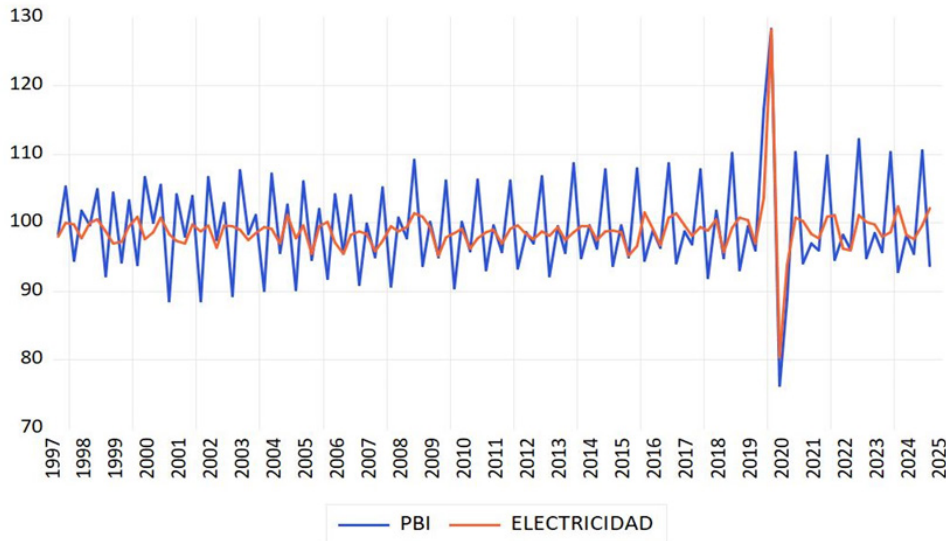
El análisis descriptivo también permite identificar un comportamiento de la demanda de electricidad que tiende a repetirse, con puntos altos (crestas) en cada trimestre 3 y 4 de cada año, mientras que los dos primeros trimestres tienden a presentar valores bajos. Esta situación muestra un comportamiento estacional de la serie analizada. En este sentido, es pertinente la aplicación de un modelo ARIMAX Estacional (SARIMAX) de tal manera que en las estimaciones se contemple componentes autorregresivos y de medias móviles estacionales, que complementen a los componentes regulares de un modelo ARMA.

Además, el análisis de series de tiempo requiere una estacionariedad débil, es decir, que la variable analizada tenga una media y una varianza estables a lo largo del tiempo, y que la correlación de la variable

con cada uno de sus rezagos también es estable a lo largo del tiempo (Ghysels & Marcellino, 2018). De este modo, para verificar la estacionariedad de la serie de la demanda de electricidad, se realizó un análisis visual del correlograma (en el Anexo 1 se presenta el correlograma de la serie original). En ésta se observa una caída lenta de la función de la autocorrelación simple, mientras que la función de autocorrelación parcial si presenta una caída drástica después del primer rezago. Estas características son propias de una serie no estacionaria. En este sentido, para garantizar la estacionariedad de la serie, se transformaron los datos a sus tasas de variación, equivalentes a cambios relativos entre periodos consecutivos. Estos resultados se presentan en la Figura 2. Esta transformación cumple una función análoga a la primera diferencia, al eliminar la tendencia de la serie y estabilizar la varianza.

Figura 2

Tasa de Crecimiento Trimestral de Electricidad y PBI



Nota: Elaborado con datos del BCRP

Estimación y evaluación de la robustez del modelo

De acuerdo con la metodología descrita se realizó la estimación de modelos, a través de la interacción de diferentes combinaciones de orden autorregresiva y de media móvil, tanto para la parte regular como estacional, incluyendo como

variable exógena el PBI. Además, para la selección del modelo, se empleó el Criterio de Información de Schwarz, también denominado Criterio de Información Bayesiano (BIC). Desarrollado los cálculos y las comparaciones, se obtuvo el modelo ARIMAX Estacional (2,1,2) (1,0,1) [4], el mismo que tiene el mínimo criterio de información de Schwarz. Los resultados se presentan en la Tabla 1.

Tabla 1

Estimación del Mejor Modelo: Modelo ARIMAX Estacional – SARIMAX (2,1,2)(1,0,1)[4]

Variable	Coficiente	Error estándar	Estadístico t	Prob.
C	0.004693	0.000978	4.796723	0.0000
G_PBI	0.710841	0.020042	35.46831	0.0000
AR(1)	0.018746	0.017710	1.058499	0.2923
AR(2)	-0.985229	0.019247	-51.18807	0.0000
SAR(1)	-0.999802	0.000506	-1976.351	0.0000
MA(1)	-0.033457	0.089717	-0.372914	0.7100
MA(2)	0.597699	0.088222	6.774945	0.0000
SMA(1)	0.931628	0.058444	15.94063	0.0000
SIGMASQ	0.000143	2.02E-05	7.095542	0.0000
R2	0.886380		Observaciones	111
R2 ajustado	0.877468		Crit. de Akaike	-5.769561
Estadístico F	99.46584		Crit. de Schwartz	-5.549869
Prob (Estad. F)	0.000000		Crit. de H-Q	-5.680439

Nota: Elaborado con datos del BCRP

Como se observa en la Tabla 1, la inclusión del PBI como variable exógena, es estadísticamente significativa. Además, para verificar la pertinencia del uso del modelo SARIMAX, se contrastó con un modelo ARIMA, seleccionado en base al mismo criterio descrito anteriormente (Criterio de Información de Schwarz). Los cálculos realizados, muestran que el Modelo ARIMA (1,1,1) [4] es el que minimiza el respectivo criterio de información.

Los resultados se muestran en la Tabla 2, donde se verifica que su valor BIC es de -3.8539, el mismo que es mayor al BIC obtenido al Modelo ARIMAX Estacional (2,1,2) (1,0,1) [4] de -5.5499 presentada en la Tabla 1. En base a este último fundamento descrito, se corrobora la inclusión del PBI como variable exógena, ya que permite mejorar la capacidad predictiva de nuestra estimación.

Tabla 2*Modelo ARIMA(1,1,1)[4] - Sin Variable Exógena*

Variable	Coefficiente	Error estándar	Estadístico t	Prob.
C	0.013221	0.002041	6.477553	0.0000
AR(1)	0.301106	0.116568	2.583107	0.0111
MA(1)	-0.737754	0.101576	-7.263042	0.0000
SIGMASQ	0.001044	4.61E-05	22.66032	0.0000
R2	0.173445		Observaciones	111
R2 ajustado	0.150271		Crit. de Akaike	-3.951609
Estadístico F	7.484325		Crit. de Schwartz	-3.853968
Prob (Estad. F)	0.000135		Crit. de H-Q	-3.911999

Nota: Elaborado con datos del BCRP**Pronóstico**

Una vez verificada la pertinencia del método empleado y seleccionado el mejor Modelo, se procede a realizar el pronóstico de la demanda trimestral de la electricidad. Para tal efecto y como paso previo, se realizó la predicción del PBI para un horizonte de mediano plazo, de tal manera que pueda ser incluida como variable exógena en el modelo SARIMAX seleccionado. Esta predicción fue realizada mediante un modelo ARIMA (3,1,5) [4] y su estimación se presenta en el Anexo 2.

Realizado el pronóstico del PBI como variable exógena de nuestro modelo, se procedió a la predicción de la demanda trimestral de electricidad en el Perú. El horizonte temporal para el pronóstico comprende del tercer trimestre del 2025 al segundo trimestre del año 2028, haciendo un total de 12 periodos. Los resultados del pronóstico se muestran en la Tabla 3, el mismo que se complementa con la Figura 3, donde aprecia que la demanda de electricidad continuará con una tendencia creciente durante los siguientes 12 trimestres (3 años).

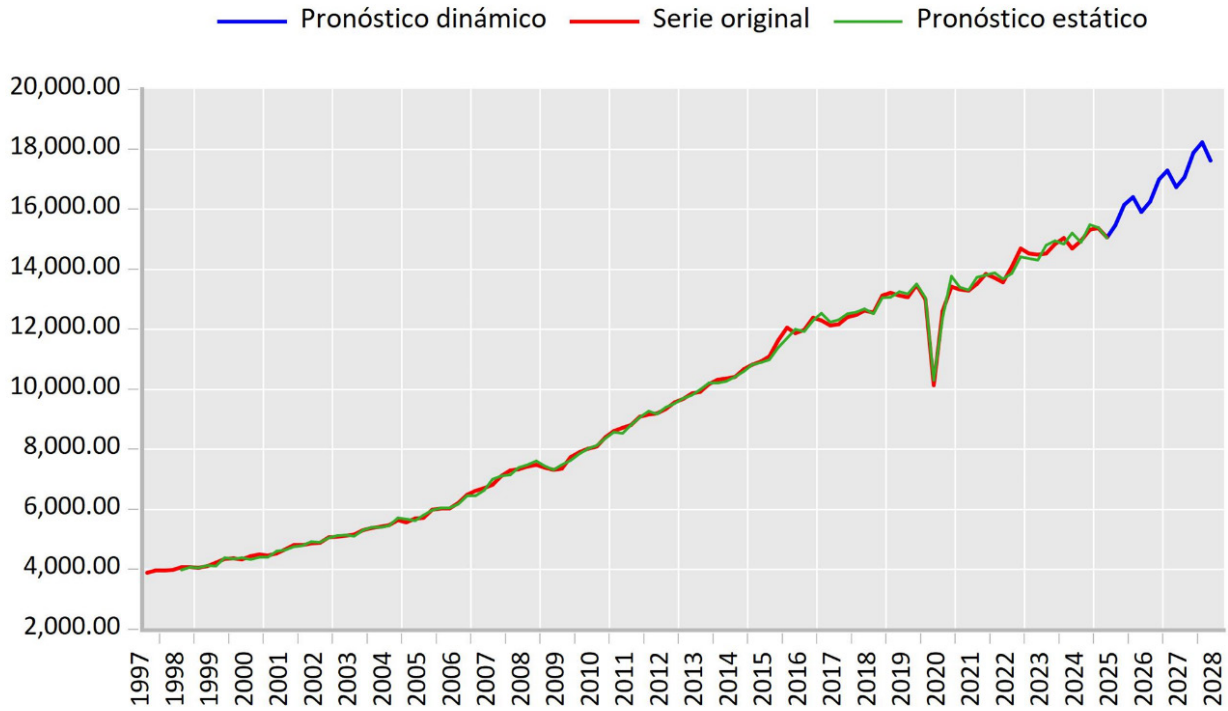
Tabla 3*Pronóstico Dinámico de la Demanda de Electricidad (GWH) 2025 T3 – 2028 T2*

Periodo	Trimestre	Demanda de electricidad
1	2025 T3	15 481.19
2	2025 T4	16 150.71
3	2026 T1	16 405.79
4	2026 T2	15 916.62
5	2026 T3	16 265.07
6	2026 T4	16 997.64
7	2027 T1	17 297.90
8	2027 T2	16 751.84
9	2027 T3	17 085.66
10	2027 T4	17 882.41
11	2028 T1	18 236.91
12	2028 T2	17 633.20

Nota: Elaborado con datos del BCRP

Figura 3

Pronóstico de la Demanda de Electricidad y ajuste del modelo (GWH) 2025 T3 – 2028 T2



Nota: Elaborado con datos del BCRP

Discusión

La metodología empleada ha permitido realizar la predicción de la demanda de electricidad para un horizonte de mediano plazo. La inclusión del PBI como variable exógena, permitió obtener un valor más bajo del Criterio de Información de Schwarz, en comparación a un modelo ARIMA (sin variable exógena). Así, la predicción realizada en base al modelo SARIMAX seleccionado, permite anticipar el comportamiento de la demanda de electricidad en el Perú hasta el segundo trimestre del año 2028. Según el pronóstico, la tasa de crecimiento interanual promedio de la demanda de electricidad será de 4.99% en los siguientes 12 trimestres. Estas

estimaciones, similar a la estimada por Cabrera Torres (2023), permiten a los responsables políticos anticipar las necesidades futuras de electricidad y planificar proyectos de generación y distribución de manera más eficiente. La planificación energética puede basarse en estas proyecciones para orientar inversiones en generación y distribución eléctrica, asegurando un desarrollo sostenible del sector. Además, se podrían promover inversiones mediante Asociaciones Público-Privadas (APP), incentivando la participación tanto de inversores nacionales como extranjeros.

Finalmente es conveniente algunas propuestas para la agenda de futuras investigaciones. Es conveniente la exploración de variables exógenas adicionales, como indicadores demográficos, precios de electricidad o factores climáticos, para a fin de evaluar si éstos mejoran la precisión de los modelos. Del mismo modo, es recomendable analizar el comportamiento de la demanda de electricidad a nivel regional en el Perú, identificando diferencias entre zonas urbanas y rurales y su impacto en las proyecciones nacionales. Otro ámbito que requiere mayor profundización es el análisis comparativo de distintas técnicas estadísticas para la realización de pronósticos. Por ejemplo, en otros contextos, la aplicación de técnicas híbridas que combinan Redes Neuronales Artificiales con modelos ARIMAX ha mostrado resultados satisfactorios en términos de precisión predictiva (Almaleck et al., 2024).

Conclusiones

El análisis descriptivo de la serie de tiempo de la demanda de electricidad en el Perú evidenció un comportamiento estacional, caracterizado por picos en los trimestres tercero y cuarto de cada año, mientras que los dos primeros trimestres presentan niveles de consumo relativamente menores. Asimismo, el diagrama de dispersión entre la demanda de electricidad y el PBI mostró una relación positiva significativa, con un coeficiente de correlación de Pearson de 0,9866, lo que confirma la fuerte asociación entre ambas variables. Esta relación fue uno de los criterios fundamentales para incorporar el PBI como variable exógena en el modelo de pronóstico de la demanda eléctrica.

El modelo SARIMAX (2,1,2)(1,0,1) [4], que incorpora el PBI como variable exógena, mostró un mejor desempeño en comparación con el modelo ARIMA univariante, al reducir significativamente el Criterio de Información de Schwarz (BIC), pasando de -3.8539 a -5.5499 . En

base a este último fundamento descrito, se corrobora la inclusión del PBI como variable exógena, ya que permite mejorar la capacidad predictiva del modelo de demanda de electricidad.

Finalmente, el pronóstico de la demanda de electricidad proyecta un crecimiento sostenido hasta el segundo trimestre de 2028, con una tasa de crecimiento interanual promedio de 4,99 % durante los próximos doce trimestres. De este modo, a través de la disponibilidad de información confiable y oportuna, se contribuye a una mejor toma de decisiones por parte de los agentes económicos, en particular para aquellos involucrados en el sector energético peruano.

Bibliografía

- Alharbi, F. R., & Csala, D. (2022). A Seasonal Autoregressive Integrated Moving Average with Exogenous Factors (SARIMAX) Forecasting Model-Based Time Series Approach. *Inventions*, 7(4). <https://doi.org/10.3390/inventions7040094>
- Almaleck, P., Massucco, S., Mosaico, G., Saviozzi, M., Serra, P., & Silvestro, F. (2024). Electrical consumption forecasting in sports venues: A proposed approach based on neural networks and ARIMAX Models. *Sustainable Cities and Society*, 100, 105019. <https://doi.org/10.1016/j.scs.2023.105019>
- Amézquita Bravo, C. C. (2021). *Evaluación de modelos de series de tiempo para pronosticar la demanda de transporte aéreo a corto y mediano plazo en Colombia* [Evaluación de modelos de series de tiempo para pronosticar la demanda de transporte aéreo a corto y mediano plazo en Colombia] [Universidad Nacional de Colombia]. <https://repositorio.unal.edu.co/items/9dbef629-fb4d-4605-abd2-bd09c2560a7d>

- Box, G. E. P., Jenkins, G. M., Jenkins, G. C., & Ljung, G. M. (2016). *Time Series Analysis: Forecasting and Control* (5th ed.). John Wiley & Sons, Inc.
- Cabrera Torres, W. L. (2023). *Evidencia y pronóstico del consumo de electricidad y crecimiento económico para aportes en políticas de electricidad en Perú – 2023* [Universidad Nacional Pedro Ruiz Gallo]. <https://repositorio.unprg.edu.pe/handle/20.500.12893/13669>
- Cai, M., Pipattanasomporn, M., & Rahman, S. (2019). Day-ahead building-level load forecasts using deep learning vs. traditional time-series techniques. *Applied Energy*, 236(October 2018), 1078–1088. <https://doi.org/10.1016/j.apenergy.2018.12.042>
- Colina-Calvo, A. O. (2024). A Comprehensive Review of Peru's Energy Scenario: Advancing Energy Access, Sustainability, and Policy Implications. *Revista Kawsaypacha: Sociedad y Medio Ambiente*, 2024(14), 1–24. <https://doi.org/10.18800/kawsaypacha.202402.D006>
- Damián Llatas, M. R., & Sandoval Santamaría, N. J. (2019). *Modelo óptimo de Pronóstico del índice mensual de Producción de Electricidad”-Perú en el Periodo 2006 – 2015* [Universidad Nacional Pedro Ruiz Gallo]. <https://hdl.handle.net/20.500.12893/2192>
- Enders, W. (2014). *Applied Econometric Time Series* (4th ed.). John Wiley & Sons, Inc.
- Ghysels, E., & Marcellino, M. (2018). *Applied Economic Forecasting using Time Series Methods*. Oxford University Press. <https://file-lianxh.oss-cn-shenzhen.aliyuncs.com/Refs/Books/Ghysels-2018-Applied-Economic-Forecasting-using-Time-Series-Methods.pdf>
- Gonzales Chávez, S. (2014). Pronóstico eficiente de la demanda diaria del Sistema Electrico Interconectado del Peru mediante analisis estocastico ARIMA con sucesos externos. *Revistas.Uni.Edu.Pe*, 12. <https://doi.org/10.21754/tecnia.v24i1.35>
- Guevara Bernal, I. A., & Guevara Bernal, N. M. (2019). *Pronóstico de la relación entre tasa de subempleo subjetivo por competencias y la tasa desempleo en Colombia entre enero del 2010 hasta diciembre de 2018 mediante un modelo ARIMAX de series de tiempo*. [Fundación Universitaria Los Libertadores]. <https://repositorio.libertadores.edu.co/items/c8f12cd4-8a18-4178-968d-6a0d28ee4479>
- Hansen, B. E. (2017). Time series econometrics for the 21st century. *Journal of Economic Education*, 48(3), 137–145. <https://doi.org/10.1080/00220485.2017.1320610>
- Hernández Sampieri, R., & Mendoza Torres, C. P. (2018). *Metodología de la investigación: las tres rutas cuantitativa, cualitativa y mixta*. Mc Graw Hill. <http://repositorio.uasb.edu.bo/handle/20.500.14624/1292>
- Lee, G. C. (2025). A Data-Driven Approach to Tourism Demand Forecasting: Integrating Web Search Data into a SARIMAX Model. *Data*, 10(5). <https://doi.org/10.3390/data10050073>

Levendis, J. D. (2023). *Time Series Econometrics: Learning Through Replication* (2nd ed.). Springer Cham. <https://doi.org/10.1007/978-3-031-37310-7>

Manigandan, P., Alam, M. S., Alharthi, M., Khan, U., Alagirisamy, K., Pachiyappan, D., & Rehman, A. (2021). Forecasting natural gas production and consumption in united states-evidence from sarima and sarimax models. *Energies*, 14(19), 1–17. <https://doi.org/10.3390/en14196021>

Ruiz Roldán, K. J., & Mimbela Jiménez, M. A. (2021). *Análisis del Sector energía eléctrica en el Perú* (Issue Mayo) [Universidad de Piura]. <https://hdl.handle.net/11042/5092>

Sarpong-Streeter, R. M. N. Y., Sokkalingam, R., Othman, M., Daud, H., & Owusu, D. A. (2021). ARIMAX Modelling of Ron97 Price with Crude Oil Price as an Exogenous Variable in Malaysian. *Springer Proceedings in Complexity*, 679–691. https://doi.org/10.1007/978-981-16-4513-6_59

Anexos

Anexo 1

Modelo ARIMA (3,1,5)[4] para el Pronóstico del PBI (Variable Exógena)

Dependent Variable: G_PBI
 Method: ARMA Maximum Likelihood (BFGS)
 Date: 10/25/25 Time: 06:47
 Sample: 1997Q4 2025Q2
 Included observations: 111
 Convergence achieved after 451 iterations
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.012009	0.003009	3.991512	0.0001
AR(1)	-0.947018	0.048692	-19.44929	0.0000
AR(2)	-0.942141	0.057342	-16.43007	0.0000
AR(3)	-0.994120	0.021344	-46.57615	0.0000
MA(1)	0.557564	21.44728	0.025997	0.9793
MA(2)	0.351257	24.28626	0.014463	0.9885
MA(3)	0.462103	10.98013	0.042085	0.9665
MA(4)	-0.538683	43.94895	-0.012257	0.9902
MA(5)	-0.277297	32.18735	-0.008615	0.9931
SIGMASQ	0.001649	0.081851	0.020151	0.9840
R-squared	0.671855	Mean dependent var	0.011833	
Adjusted R-squared	0.642615	S.D. dependent var	0.071220	
S.E. of regression	0.042576	Akaike info criterion	-3.304715	
Sum squared resid	0.183086	Schwarz criterion	-3.060613	
Log likelihood	193.4117	Hannan-Quinn criter.	-3.205690	
F-statistic	22.97680	Durbin-Watson stat	2.000765	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.03-1.00i	.03+1.0	-1.00	
Inverted MA Roots	.70	.06+1.0	.06-1.00i	-.41
	-.97			

Nota: Elaborado con datos del BCRP.

Anexo 2

Correlograma Serie Original de la Demanda de Electricidad

Date: 10/25/25 Time: 18:49

Sample (adjusted): 1997Q3 2025Q2

Included observations: 112 after adjustments

	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.973	0.973	108.88	0.000		
2	0.947	0.001	212.89	0.000		
3	0.924	0.054	312.87	0.000		
4	0.901	-0.011	408.85	0.000		
5	0.877	-0.032	500.62	0.000		
6	0.851	-0.044	587.90	0.000		
7	0.828	0.032	671.30	0.000		
8	0.805	-0.021	750.80	0.000		
9	0.779	-0.051	826.01	0.000		
10	0.753	-0.024	896.94	0.000		
11	0.728	0.001	963.89	0.000		
12	0.704	0.001	1027.1	0.000		
13	0.680	-0.007	1086.7	0.000		
14	0.654	-0.035	1142.5	0.000		
15	0.630	-0.008	1194.6	0.000		
16	0.606	0.002	1243.4	0.000		
17	0.580	-0.046	1288.7	0.000		
18	0.556	0.001	1330.7	0.000		
19	0.532	-0.007	1369.5	0.000		
20	0.510	0.032	1405.6	0.000		
21	0.497	0.134	1440.2	0.000		
22	0.472	-0.211	1471.8	0.000		
23	0.445	-0.038	1500.2	0.000		
24	0.419	-0.041	1525.6	0.000		
25	0.391	-0.056	1548.0	0.000		
26	0.363	-0.019	1567.6	0.000		
27	0.336	0.014	1584.5	0.000		
28	0.310	-0.019	1599.1	0.000		
29	0.283	-0.045	1611.5	0.000		
30	0.257	0.010	1621.7	0.000		
31	0.230	-0.015	1630.1	0.000		
32	0.205	-0.010	1636.8	0.000		
33	0.178	-0.049	1641.9	0.000		
34	0.151	-0.032	1645.6	0.000		
35	0.124	-0.024	1648.1	0.000		
36	0.097	-0.016	1649.7	0.000		

Nota: Elaborado con datos del BCRP.