

Aplicación de un Modelo de Series de Tiempo para el pronóstico de la Tasa de Inflación del Perú.

Application of a Time Series Model for Peru's Inflation Rate Forecast.

Palabras clave:

Inflación
Pronóstico
Estabilidad
Modelo ARIMA

Keywords:

Inflation
Forecast
Stability
ARIMA model

Fecha de recepción:

20 de agosto de 2023

Fecha de aceptación:

15 de diciembre de 2023

RESUMEN

La presente investigación tuvo como objetivo estimar un modelo para la obtención de pronósticos confiables de la tasa de inflación para un horizonte a mediano plazo. La estabilidad de precios es condición necesaria para el desarrollo de las actividades económicas y constituye uno de los objetivos macroeconómicos fundamentales. Con información histórica de una serie mensual de la tasa de inflación, para el periodo enero 2013 a setiembre 2023, y la aplicación del método de Box y Jenkins, se estima un modelo SARIMA (1,1,1) (0,0,1) [12]. Los resultados permiten contar con información confiable y oportuna para la adecuada toma de decisiones por parte de los agentes económicos y los responsables de la política económica en nuestro país.

Sebastian Rolando Ayala-Beas

E-mail: sayalab@unasam.edu.pe

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

Carlos Enrique Fernández Lopez

E-mail: cfernandezl@unasam.edu.pe

 <<https://orcid.org/0000-0002-9621-4120>>

Milton César Giraldo Méndez

E-mail: mgiraldom@unasam.edu.pe

 <<https://orcid.org/0000-0003-4625-0032>>

Antonio Peregrino Huamán Osorio

E-mail: ahuamano@unasam.edu.pe

 <<https://orcid.org/0000-0002-7442-2965>>

ABSTRACT

The objective of this research was to estimate a model to obtain reliable forecasts of the inflation rate for a medium-term horizon. Price stability is a necessary condition for the development of economic activities and constitutes one of the fundamental macroeconomic objectives. With historical information from a monthly inflation rate series for the period January 2013 to September 2023 and the appli-

cation of the Box and Jenkins method, a SARIMA model (1,1,1) (0,0,1) [12] is estimated. The results provide reliable and timely information for appropriate decision-making by economic agents and economic policy makers in our country.

INTRODUCCIÓN

A pesar de que, a nivel internacional, las distintas economías se comportan de diferentes maneras, el control de la inflación destaca como uno de los objetivos macroeconómicos fundamentales (Erokhin *et al.*, 2023). Al respecto, se dice que la economía está experimentando inflación cuando los precios de la mayoría de los bienes y servicios aumentan con el tiempo (Abel *et al.*, 2024). Desde una perspectiva histórica, se mencionan registros sobre este fenómeno económico desde hace dos mil años, durante la época del Imperio Romano (King, 2023). En el caso particular de Perú, está ampliamente documentada la experiencia de inflación crónica entre las décadas de 1970 y 1980, así como la etapa de hiperinflación de 1987-1990 (Martinelli y Vega, 2018).

Las consecuencias de la inflación son diversas. Por ejemplo, las altas tasas de inflación están asociadas a menores tasas de crecimiento económico (Castillo Bardález, 2021). En este sentido, la estabilidad de precios es una condición necesaria para el desarrollo de las actividades económicas, pues permitiría preservar la capacidad adquisitiva de la moneda nacional, que procure, de este modo, favorecer la toma de decisiones por parte de los agentes económicos (Quispe Misaico, 2021). Desde 1993, la responsabilidad de lograr la estabilidad de precios está a cargo de la Banco Central de Reserva del Perú, una entidad que goza de independencia (Pérez Forero *et al.*, 2016).

Dada la importancia de esta variable en la economía, resulta interesante anticipar su comportamiento futuro. En ese sentido, una de las técnicas de la econometría de series de tiempo más usadas en las investigaciones son los modelos ARIMA, derivado del inglés *AutoRegressive Integrated Moving Average* (modelo autorregresivo integrado de media móvil). Entre los estudios a nivel internacional, destaca el realizado por Karadzic y Pejovi (2021), quienes concluyeron que para el caso de la Unión Europea, los modelos ARIMA dan el pronóstico más preciso de los valores futuros de inflación, debido a la implementación por parte del Banco Central Europeo con una política de estrictas metas de inflación durante mucho tiempo.

En el contexto nacional, Arana Cerna *et al.* (2021) realizaron un pronóstico para el índice de precios al consumidor de Lima Metropolitana. Con información de una serie mensual que inició en enero de 2010 hasta diciembre

de 2020 y aplicando la metodología de Box – Jenkins, identifican un modelo de tipo SARIMA (0,1,1) (1,0,1)₁₂., concluyeron que los errores, cercanos a cero, demuestran que el pronóstico realizado no presenta sesgo.

En este sentido, la presente investigación tiene como objetivo estimar un modelo para obtener pronósticos confiables de la tasa de inflación para un horizonte a mediano plazo. Para tal efecto, la investigación inicia con una sección introductoria donde se describe algunas características de la variable de estudio, así como una breve revisión de investigaciones previas. En un segundo apartado se aborda el aspecto metodológico de la investigación. Luego, en la sección de resultados, se presentan las estimaciones de cuatro modelos propuestos, y se realiza el pronóstico en base al mejor modelo identificado. Finalmente se realiza la discusión de los hallazgos y se presentan las principales conclusiones del estudio.

MÉTODOS Y DATOS

Econometría de Series de Tiempo

Una serie de tiempo es una secuencia de observaciones registradas durante un período temporal (Subba Rao, 2022). Desde el enfoque econométrico, el análisis de series de tiempo se puede dividir en dos ramas principales: el pronóstico y el modelado dinámico. Así pues, el pronóstico significa predecir los valores futuros en base a la comprensión de la distribución de datos anteriores, a través de un análisis univariado o un análisis multivariado. Por otro lado, en el modelado dinámico, se construye modelos econométricos para investigar la relación, probar la hipótesis y validar la teoría (Jalil & Rao, 2019). En la presente investigación, dado el objetivo planteado y el análisis univariado del estudio, se empleó la categoría del pronóstico.

Modelos ARIMA y ARIMA Estacional (SARIMA)

En 1976, Box y Jenkins popularizaron el uso de modelos de series de tiempo univariadas para realizar pronósticos, especialmente en el ámbito económico y financiero (Ghysels & Marcellino, 2018). Una característica intrínseca de una serie de tiempo es que, normalmente, las observaciones adyacentes son dependientes. El análisis de series de tiempo se ocupa de técnicas para el estudio de la naturaleza de esta dependencia entre las observaciones, dado su considerable interés práctico (Box *et al.*, 2016). En concreto, ARIMA se refiere a un modelo autorregresivo integrado de promedio móvil, que emplea las relaciones entre los datos, de este modo, se identifican los patrones intrínsecos en la serie y, en base a estos, se realiza un pronóstico de los mismos (López Sáez, 2018).

En general, estos modelos se especifican con el término ARIMA (p, d, q), donde (p) hace referencia al orden del modelo autorregresivo; (d), al término de diferenciación, y (q), al orden de media móvil con q términos de error (Hyndman y Athanasopoulos, 2018). Respecto a su especificación, el modelo ARIMA (p, d, q) puede ser representado por la siguiente ecuación general (Kumar y Baishya, 2020):

$$y_t = \mu + \sum_{i=1}^p \varphi_i y_{t+i} + \sum_{j=1}^q \varphi_j \varepsilon_{t-j} + \varepsilon_t$$

Donde, y_t es la tasa de inflación, μ es la media de la serie, los $\varphi_1, \dots, \varphi_p$ son los parámetros del modelo autorregresivo (AR), los $\theta_1, \dots, \theta_q$ son los parámetros del modelo de media móvil (MA) y los $\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$ son los términos de error.

Por otro lado, muchos procesos económicos exhiben alguna forma de estacionalidad¹ y aquellos pronósticos que ignoren estos patrones estacionales importantes tendrán una gran variación (Enders, 2014). Para tener en cuenta la estacionalidad de la serie temporal, el modelo ARIMA estacional o SARIMA (acrónimo derivado del inglés *Seasonal Autoregressive Integrated Moving Average*) combina el ARIMA no estacional (p, d, q) con términos estacionales adicionales (P, D, Q). El término AR estacional, el término de media móvil estacional y el término de diferenciación estacional están representados, respectivamente, por los términos P, Q y D; cuya especificación general es la siguiente (Andueza *et al.*, 2023):

$$\varphi_p(B^m)\varphi_p(B)(1-B^m)^D(1-B)^d Y_t = \theta_Q(B^m)\theta_q(B)W_t$$

Donde y_t es la serie temporal no estacionaria, w_t es el proceso de ruido blanco, $\varphi(B)$ es un polinomio autorregresivo no estacional y $\theta(B)$ es un polinomio de media móvil no estacional, D es la diferenciación estacional, $\varphi(B^m)$ es un polinomio autorregresivo estacional y $\theta(B^m)$ es un polinomio de media móvil estacional. Donde B se define como el operador de retroceso el cual se expresa de la siguiente manera:

¹ Se denomina estacionalidad a un patrón presente en una serie temporal que se repite periódicamente cada s intervalos de tiempo. Por ejemplo, un conjunto de datos mensuales presenta estacionalidad cuando los valores altos tienden a suceder habitualmente en un mes específico. En este caso, $s=12$ representaría el comportamiento estacional (Guerra Rodríguez, 2022).

$$B^k y_t = y_{t-k}$$

Para la estimación de un modelo ARIMA o SARIMA, el método Box-Jenkins aplica una estrategia iterativa que comprende 4 pasos (Muñoz-Santiago *et al.*, 2017). En principio, se identifica un modelo, con una elección tentativa de p , d y q para la parte regular; así como el P , D y Q para la parte estacional. El segundo paso consiste en la estimación de los parámetros del modelo seleccionado. En tercer lugar, se realiza el diagnóstico del modelo verificando que los residuos tienen ruido blanco. Por último, se realiza el pronóstico con el modelo validado.

Recolección de datos


La investigación es cuantitativa con diseño no experimental, de tipo longitudinal (Hernández Sampieri y Mendoza Torres, 2018). En cuanto a las técnicas de recolección de datos, la serie de tiempo se extrajo de las estadísticas existentes en la base de datos del Instituto Nacional de Estadística e Informática (INEI). El instrumento para la obtención de información de la variable de estudio son los reportes digitales en formato Excel que emite la sección de series estadísticas de la página web del INEI (2023) y corresponde a una serie mensual de la tasa de inflación (variación anual del IPC a nivel nacional) del Perú para el periodo enero 2013 a setiembre 2023 y representa una serie de 129 observaciones. El procesamiento de los datos fue realizado empleando el lenguaje de programación *R* y el software *RStudio*.

RESULTADOS

Para el procesamiento estadístico primero, se elaboró la figura 1 que permita analizar visualmente el comportamiento de la inflación durante el horizonte temporal. Complementariamente, se realizó la descomposición clásica multiplicativa de la serie de tiempo para identificar cuatro categorías: tendencia, variación estacional, variación cíclica y el componente irregular o ruido (Jalil y Rao, 2019). En la parte superior de la figura 1, se presenta la serie observada. Respecto a la tendencia, resulta creciente al final del horizonte analizado que refleja el continuo incremento de los precios a partir del 2020 y se muestra una pendiente más pronunciada. Por otro lado, también se logra identificar ligeros patrones de cambio que tiendan a repetirse durante cada año (hay evidencia de estacionalidad). Finalmente, no se observan cambios relevantes en la varianza.

Figura 1

Perú: Descomposición de la tasa de inflación interanual (enero 2013 – setiembre 2023)



Fuente: Elaboración propia con información del INEI

Para el análisis de estacionariedad de la serie, se aplicó la prueba Dickey-Fuller (DF) para raíz unitaria. En ella, se plantea la hipótesis nula H_0 : la serie de tiempo tiene raíz unitaria (no estacionarias); frente a la hipótesis nula H_a : las series temporales no siguen la raíz unitaria (estacionaria); donde si el p valor de ADF es mayor a 0,05, no se rechaza la H_0 (Eissa, 2020). Los resultados de esta prueba dan un p-valor de 0,902, mayor al nivel de significancia de 0,05, lo que implica que nuestra serie no es estacionaria (no rechazamos H_0). Los modelos ARIMA, y en general el análisis estadístico significativo, requiere el supuesto de estacionariedad (Deistler y Scherrer, 2022). En este sentido, corresponde convertir la serie observada a una serie estacionaria mediante una diferenciación de orden d .


Una vez aplicada la primera diferencia a la serie original de la tasa de inflación interanual, luego se ejecuta la prueba DF que obtiene la estacionariedad de la serie, con un p valor de 0,01 en la prueba DF. Así, en la figura 2, se presenta la serie estacionarizada, con su respectiva gráfica de función de autocorrelación simple (ACF) y autocorrelación parcial (PACF).

La función de autocorrelación simple y autocorrelación parcial son útiles para decidir los valores apropiados de p y q . En particular, la función de autocorrelación simple, ayuda a elegir los valores apropiados para el orden q de los

términos de media móvil (MA) y la función de autocorrelación parcial para los términos p autorregresivos (AR) (Kumar y Baishya, 2020). Para los parámetros P y Q de la parte estacional, se determinan iterativamente evaluándolos de forma similar a la parte regular del modelo (El Habib, 2020). Del análisis de los correlogramas de la figura 2, se plantea los siguientes modelos SARIMA que serán estimados y comparados: Modelo 1: SARIMA (1,1,1) (0,0,1) [12], Modelo 2: SARIMA (1,1,1) (1,0,0) [12], Modelo 3: SARIMA (1,1,1) (1,0,1) [12] y el Modelo 4: SARIMA (1,1,1) (1,0,2) [12], el último fue recomendado por la función de Auto.Arima de R (Huertas y Donado, 2018).

Figura 2

Serie estacionaria de la tasa de inflación, autocorrelación simple y autocorrelación parcial



Fuente: Elaboración propia con información del INEI

Para la selección del mejor modelo, se aplica el Criterio de Información de Akaike (AIC), Criterio de Información de Akaike Corregido (AICc) y el Criterio de Información de Bayesiano (BIC) que son ampliamente aceptados como métodos objetivos y adecuados para la identificación y estimación de modelos bajo el marco ARIMA, siendo preferible el AICc (Hyndman y Athanasopoulos, 2018). Los resultados se muestran en la tabla 1, donde para cada uno de los 4 modelos comparados, se incluyen los valores obtenidos del AIC, AICc y BIC. Del análisis sobre los criterios establecidos previamente, se deduce que el

mejor es el Modelo 1 SARIMA (1,1,1) (0,0,1) [12], debido a que este modelo minimiza los valores de AIC, AICc y BIC. En este sentido, en la misma tabla 1, se muestra la estimación del Modelo 1.

Tabla 1

Comparación y selección del mejor modelo SARIMA para el pronóstico de la inflación

Modelo	AIC	AICc	BIC	Estimación del mejor modelo: Modelo 1 SARIMA (1,1,1) (0,0,1) [12]
Modelo 1: (1,1,1) (0,0,1) [12]	41,59	41,92	53	ARIMA(1,1,1)(0,0,1)[12] Coefficients: ar1 ma1 sma1 0.9359 -0.7118 -1.0000 s.e. 0.0509 0.0957 0.1284 sigma^2 = 0.06213: log likelihood = -16.8 AIC=41.59 AICc=41.92 BIC=53
Modelo 2: (1,1,1) (1,0,0) [12]	75,53	75,85	86,93	
Modelo 3: (1,1,1) (1,0,1) [12]	42,91	43,4	57,17	
Modelo 4: (1,1,1) (1,0,2) [12]	43,97	44,66	61,08	

Una vez seleccionado el modelo, el siguiente paso del método Box-Jenkins es la realización del diagnóstico del modelo que verifica los residuos tienen ruido blanco. En este sentido, para la validación del modelo, se realizó la prueba de Ljun-Box. Los resultados muestran un p-valor de 0,1569 que es mayor al nivel de significancia de 0,05, e implica un buen ajuste de nuestro modelo, es decir, que los residuos presentan una media igual a cero, varianza constante y no están correlacionados.

Finalmente, se realiza el pronóstico con el modelo validado. Por tanto, en la tabla 2, se presenta el pronóstico de la tasa de inflación para el horizonte de mediano plazo de 18 meses, de octubre 2023 a marzo 2025 (se incluye al mes de octubre del año 2023, momento en que se realiza la presente investigación). En la tabla 2, se detalla los valores del pronóstico puntual de la tasa de inflación nacional. Se incluye, además, los pronósticos con un nivel de confianza del 80 % y 95 %, con sus respectivos límites superior e inferior para cada intervalo.

Tabla 2

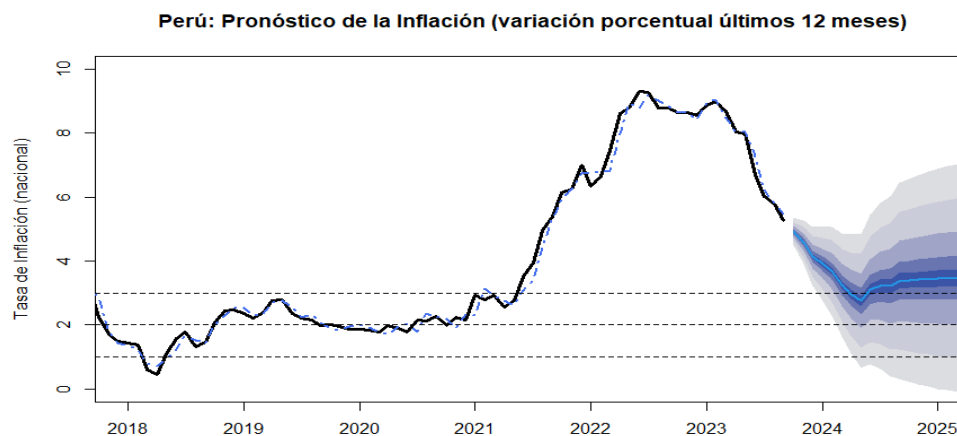
*Pronóstico de la tasa de inflación octubre 2023 - marzo 2025
 (variación porcentual últimos 12 meses)*

Año	Mes	Pronóstico puntual	Intervalo al 80 %		Intervalo al 95 %	
			Límite inferior	Límite superior	Límite inferior	Límite superior
2023	Octubre	4,92	4,59	5,26	4,41	5,43
	Noviembre	4,59	4,06	5,12	3,78	5,39
	Diciembre	4,15	3,44	4,86	3,06	5,23
2024	Enero	3,91	3,02	4,81	2,55	5,28
	Febrero	3,69	2,61	4,77	2,04	5,34
	Marzo	3,25	1,99	4,52	1,32	5,18
	Abril	2,97	1,52	4,42	0,75	5,19
	Mayo	2,75	1,11	4,39	0,25	5,25
	Junio	3,11	1,28	4,93	0,32	5,90
	Julio	3,22	1,21	5,24	0,14	6,30
	Agosto	3,21	1,01	5,41	-0,16	6,58
	Setiembre	3,38	0,99	5,77	-0,27	7,03
	Octubre	3,40	0,92	5,87	-0,39	7,19
	Noviembre	3,41	0,86	5,97	-0,49	7,32
	Diciembre	3,43	0,81	6,05	-0,58	7,44
2025	Enero	3,44	0,76	6,12	-0,65	7,54
	Febrero	3,46	0,73	6,19	-0,72	7,63
	Marzo	3,47	0,70	6,24	-0,77	7,71

Fuente: Elaboración propia

De forma complementaria, en la figura 3, se muestra el fan chart (gráfico de abanico) (Winkelried, 2012), que evidencia la serie histórica, el ajuste del modelo estimado y el pronóstico de la tasa de inflación. Como se puede apreciar, las bandas del abanico se hacen más amplias conforme transcurre el tiempo, lo que evidencia que el pronóstico va perdiendo precisión a medida que se amplía su horizonte. También se incluyen las bandas (líneas punteadas) del rango meta de inflación del BCRP.

Figura 3



Fuente: Elaboración propia

DISCUSIÓN

Las estimaciones muestran que la tasa de inflación nacional, en el Perú, seguirá una tendencia descendiente en los siguientes tres meses del presente año, que cerrará el 2023 con una tasa de 4,15 %. Según los resultados, se espera que en abril de 2024 se logre estar dentro del rango meta de inflación, es decir entre el 2 % a 3 % (Montoro *et al.*, 2022; Pérez Forero, 2017). Este pronóstico es mayor a la proyección realizada por el BCRP, que estimó cerrar el 2023 con una tasa de inflación 3,8%, pero similar en el sentido de alcanzar el rango meta de inflación durante los primeros meses del 2024 (Banco Central de Reserva del Perú, 2023). Una posible explicación de la ligera diferencia entre los resultados de la presente investigación y las proyecciones realizadas por el BCRP, es que este último emplea el IPC de Lima Metropolitana y no el IPC Nacional para estimación de la tasa de inflación.

Además, el modelo SARIMA (1,1,1) (0,0,1) [12] del presente estudio, exhibe cierta diferencia respecto al modelo SARIMA (0,1,1) (1,0,1) [12] estimado por Arana Cerna *et al.* (2021) para el pronóstico del IPC mensual de Lima Metropolitana. Por ejemplo, comparativamente, en nuestra estimación se incorpora un coeficiente autorregresivo en la parte regular del modelo, pero elimina el coeficiente autorregresivo de la parte estacional. No obstante, bajo el

principio de parsimonia², podemos concluir que ambos modelos son equivalentes para fines del pronóstico.

Para finalizar, el pronóstico realizado evidencia que la tasa de inflación tenderá a estabilizarse a partir de segundo semestre de 2024. No obstante, estas estimaciones cuantitativas deben complementarse con el análisis del contexto nacional e internacional. Por ejemplo, es pertinente evaluar aspectos como la evolución de los precios internacionales de la energía o los alimentos, que pueden tener algún impacto significativo y permanente sobre la inflación, particularmente, en el largo plazo (Espinoza Ipanaque, 2023). En este sentido, corresponde la actualización el modelo estimado y se planteen nuevas especificaciones que permita contar con pronósticos más confiables. Esta labor resulta interesante para ser abordado en siguientes investigaciones. Del mismo modo, otra posible línea de investigación es la aplicación de otros enfoques estadísticos de pronósticos, como el realizado por Álvarez García y Velita Zorrilla (2022), que permita disponer de información para futuros análisis comparativos.

² Box y Jenkins argumentan que los modelos parsimoniosos producen mejores pronósticos que los modelos sobre parametrizados. Un modelo parsimonioso se ajusta bien a los datos sin incorporar coeficientes innecesarios. Ciertamente, los pronosticadores no quieren proyectar en el futuro coeficientes mal estimados. El objetivo es aproximarse al verdadero proceso de generación de datos, pero no precisar el proceso exacto (Enders, 2014).

CONCLUSIONES

- El modelo obtenido es uno de tipo SARIMA (1,1,1) (0,0,1) [12] y con la prueba de Ljun-Box se demostró que los residuos presentan una media igual a cero, varianza constante y no están correlacionados. Al verificar un buen ajuste del modelo, se concluye que el pronóstico obtenido es confiable.
- El estudio plantea un modelo para el pronóstico de la tasa de inflación nacional del Perú, empleando información estadística obtenida del Instituto Nacional de Estadística e Informática. Esta serie mensual presenta estacionalidad y una tendencia creciente durante el periodo enero 2013 – septiembre 2023.
- Durante el desarrollo del estudio, se logró demostrar que resulta factible estimar un modelo de series de tiempo para el pronóstico de la tasa de inflación del Perú, que permita contar con información confiable y oportuna para la adecuada toma de decisiones por parte de los agentes económicos y los responsables de la política económica en nuestro país.

REFERENCIAS

- Abel, A., Bernanke, B., & Dean, C. (2024). *Macroeconomics, Global Edition* (11th ed.). Pearson Education.
- Álvarez García, A. K., & Velita Zorrilla, R. (2022). Pronóstico condicional de la inflación peruana : un enfoque Bayesiano. *Pensamiento Crítico*, 27(1), 113–135. <https://revistasinvestigacion.unmsm.edu.pe/index.php/econo/article/view/23282>
- Andueza, A., Del Arco-Osuna, M. Á., Fornés, B., González-Crespo, R., & Martín-álvarez, J. M. (2023). Using the Statistical Machine Learning Models ARIMA and SARIMA to Measure the Impact of Covid-19 on Official Provincial Sales of Cigarettes in Spain. *International Journal of Interactive Multimedia and Artificial Intelligence*, 8(1), 73–87. <https://doi.org/10.9781/ijimai.2023.02.010>
- Arana Cerna, B. E., Mena Farfán, K. V., & Núñez Caballero, A. M. (2021). Modelo Sarima Para El Pronóstico Del Índice Mensual De Precios Al Consumidor De Lima Metropolitana. *Tzhoecoen*, 13(1), 101–120. <https://doi.org/10.26495/tzh.v13i1.1876>
- Banco Central de Reserva del Perú. (2023). Panorama actual y proyecciones macroeconómicas 2023-2024. In *Reporte de inflación - Setiembre 2023*. <https://www.bcrp.gob.pe/docs/Publicaciones/Reporte-Inflacion/2023/setiembre/reporte-de-inflacion-setiembre-2023.pdf>
- Box, G., Jenkins, G., Reinsel, G., & Ljung, G. (2016). *Time Series Analysis: Forecasting and Control* (5th ed.). John Wiley & Sons, Inc.
- Castillo Bardález, P. (2021). La Estabilidad de Precios y el Crecimiento Económico: Lecciones de la Experiencia Peruana. *Económica*, 13, 137–147. <https://revistas.pucp.edu.pe/index.php/economica/article/view/25084>
- Deistler, M., & Scherrer, W. (2022). *Time Series Models*. Springer Cham. <https://doi.org/https://doi.org/10.1007/978-3-031-13213-1>
- Eissa, N. (2020). Forecasting the GDP per Capita for Egypt and Saudi Arabia Using ARIMA models. *Research in World Economy*, 11(1), 247–258. <https://doi.org/10.5430/RWE.V11N1P247>

- El Habib, E. A. J. (2020). *Análisis de Series Temporales: Uso Del Transporte Público en Barcelona* [Universidad Politécnica de Catalunya]. <https://acortar.link/O9Kxtk>
- Enders, W. (2014). *Applied Econometric Time Series* (4th ed.). John Wiley & Sons, Inc.
- Erokhin, V., Tianming, G., & Andrei, J. V. (2023). *Contemporary Macroeconomics*. Springer Singapore. https://doi.org/10.1007/978-981-19-9542-2_8
- Espinoza Ipanaque, P. C. (2023). Inflación en el Perú ante Choques de Precios Internacionales de Energía y Alimentos. *Quipukamayoc*, 31(65), 41–52. <https://doi.org/10.15381/quipu.v31i65.24508>
- 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>
- Guerra Rodríguez, J. (2022). *Fundamentos y variantes de los modelos ARIMA para el análisis de series temporales. Aplicación a la estadística universitaria*. Universidad de Laguna. <https://acortar.link/glhrM1>
- 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:8080/handle/54000/1292>
- Huertas, N., & Donado, S. (2018). *Evaluación crítica de la función AUTO.ARIMA de R en la identificación de procesos de series de tiempo* [Universidad Los Andes de Colombia]. <http://hdl.handle.net/1992/45515>
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). OTexts.
- Instituto Nacional de Estadística e Informática. (2023). *Índices de Precios*. <https://m.inei.gob.pe/estadisticas/indice-tematico/price-indexes/>
- Jalil, A., & Rao, N. H. (2019). Time Series Analysis (Stationarity, Cointegration, and Causality). In *Environmental Kuznets Curve (EKC): A Manual* (pp. 85–99). Elsevier. <https://doi.org/10.1016/B978-0-12-816797-7.00008-4>

- Karadzic, V., & Pejovic, B. (2021). Inflation Forecasting in the Western Balkans and EU: a Comparison of Holt-Winters, Arima and NNAR Models. *Amfiteatru Economic*, 23(57), 517–532. <https://doi.org/10.24818/EA/2021/57/517>
- King, S. (2023). *We Need to Talk About Inflation: 14 Urgent Lessons From the Last 2000 Years*. Yale University Press.
- Kumar, R. R., & Baishya, M. (2020). Forecasting of Potato Prices in India: An Application of ARIMA Model. *Economic Affairs (New Delhi)*, 65(4), 473–479. <https://doi.org/https://doi.org/10.46852/0424-2513.4.2020.1>
- López Sáez, J. I. (2018). *Análisis de Series de Tiempo Pronóstico de demanda de uso de aeropuertos en Argentina al 2022*. <https://ri.itba.edu.ar/server/api/core/bitstreams/46f84c43-9130-49c0-bf7e-4b41ecb051ef/content>
- Martinelli, C., & Vega, M. (2018). *La Historia Monetaria y Fiscal de Perú, 1960-2017: Experimentos Radicales de Política, Inflación y Estabilización*. <https://www.bcrp.gob.pe/docs/Publicaciones/Documentos-de-Trabajo/2018/documento-de-trabajo-007-2018-esp.pdf>
- Montoro, C., Pérez, F., & Florián, D. (2022). El esquema de metas de inflación con control de riesgos. *Revista Moneda*, 192, 22–29. <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Moneda/moneda-192/moneda-192-03.pdf>
- Muñoz-Santiago, A., Urquijo-Vanstrahlengs, J., Castro-Otero, A., & Lombana, J. (2017). Pronóstico del precio de la energía en Colombia utilizando modelos ARIMA con IGARCH. *Revista de Economía Del Rosario*, 20(1), 127–161. <https://doi.org/10.12804/revistas.urosario.edu.co/economia/a.6152>
- Pérez Forero, F. (2017). El rango meta de inflación y la efectividad de la política monetaria en el Perú. *Revista Moneda*, 169, 13–17. <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Moneda/moneda-169/moneda-169-03.pdf>
- Pérez Forero, F., Quispe Misaico, Z., & Rodríguez, D. (2016). Independencia del Banco Central y Estabilidad de Precios. *Revista Moneda*, 166, 21–28. <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Moneda/moneda-166/moneda-166-04.pdf>

- Quispe Misaico, Z. (2021). La estabilidad monetaria en el Perú. *Revista Moneda*, 188. <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Moneda/moneda-188/moneda-188-01.pdf>
- Subba Rao, S. (2022). *A Course in Time Series Analysis* (STAT 673). https://web.stat.tamu.edu/~suhasini/teaching673/time_series.pdf
- Winkelried, D. (2012). ¿Qué es un fan chart? *Revista Moneda*, 151, 32–36. <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Moneda/moneda-151/moneda-151-07.pdf>