

<https://doi.org/10.23913/ride.v16i32.2947>

Artículos científicos

Predicción del Índice Nacional de Precios al Consumidor en México

Prediction of the National Consumer Price Index in Mexico

Previsão do Índice Nacional de Preços ao Consumidor no México

Julio César Ayllon-Benítez

Tecnológico Nacional de México, México

ayllonjulio@hotmail.com

<https://orcid.org/0000-0002-5051-5411>

Resumen

Los precios al consumidor integran el indicador fundamental para medir el cambio en el costo de una canasta representativa de bienes y servicios, ponderada conforme a su importancia económica, el cual se utiliza como referencia principal para estimar la inflación. La investigación tuvo como objetivo predecir el Índice Nacional de Precios al Consumidor (INPC) empleando dos enfoques de series de tiempo: componentes no observables (UCM) y el modelo estacional autorregresivo integrado de media móvil (SARIMA) para contrastar su desempeño. Se empleó una metodología cuantitativa de tipo descriptivo y explicativo, utilizando 288 observaciones mensuales comprendidas entre enero de 2002 y diciembre de 2025. Ambos modelos fueron ajustados mediante el software estadístico SAS® y su desempeño se comparó con base en la raíz del error cuadrático medio (RECM) fuera de muestra (enero 2023 a diciembre 2025), así como los criterios de información de Akaike (AIC) y Schwarz (SBC). En los resultados, el modelo SARIMA (2,1,0)(0,1,1)[12] presentó un menor RECM, coeficientes estadísticamente significativos y valores más bajos de AIC y SBC, superando al modelo UCM. El análisis se limita a una serie temporal específica del INPC mexicano, por lo que su aplicación a otros contextos requiere precaución. La sensibilidad de UCM ante cambios estructurales plantea una ventaja en escenarios con alta volatilidad. En conclusión, el modelo SARIMA demostró mejor capacidad predictiva y

bondad de ajuste en comparación con el modelo UCM, lo que sugiere que es una herramienta eficaz para el análisis prospectivo del comportamiento inflacionario en México y para la toma de decisiones en políticas públicas.

Palabras clave: Box-Jenkins SARIMA, economía, inflación, modelos de series de tiempo.

Abstract

Consumer prices constitute the core indicator used to measure changes in the cost of a representative basket of goods and services, weighted according to their economic relevance, and serve as the main reference for estimating inflation. The objective of this study was to forecast the Mexican National Consumer Price Index (INPC) using two time series approaches: unobserved components models (UCM) and the seasonal autoregressive integrated moving average model (SARIMA), in order to compare their predictive performance. A quantitative descriptive and explanatory methodology was employed, using 288 monthly observations from January 2002 to December 2025. Both models were fitted using the SAS® statistical software, and their performance was evaluated based on out-of-sample Root Mean Squared Error (RMSE) for the period January 2023 to December 2025, as well as the Akaike Information Criterion (AIC) and Schwarz Bayesian Criterion (SBC). In the results, the SARIMA (2,1,0)(0,1,1)[12] model showed a lower RECM, statistically significant coefficients and lower AIC and SBC values, surpassing the UCM model. The analysis is limited to a specific time series of the Mexican INPC; therefore, caution should be exercised when extending the results to other contexts. The sensitivity of UCM to structural changes suggests potential advantages in scenarios with elevated volatility. In conclusion, the SARIMA model demonstrated better predictive capacity and goodness of fit compared to the UCM model, suggesting that it is an effective tool for prospective analysis of inflationary behavior in Mexico and for decision-making in public policies.

Keywords: Box-Jenkins SARIMA, economics, inflation, time series models.

Resumo



Os preços ao consumidor são o indicador fundamental para medir as variações no custo de uma cesta representativa de bens e serviços, ponderada de acordo com sua importância econômica, e são utilizados como principal referência para estimar a inflação. Esta pesquisa teve como objetivo prever o Índice Nacional de Preços ao Consumidor (INPC) utilizando duas abordagens de séries temporais: componentes não observáveis (UCM) e o modelo autorregressivo integrado de médias móveis sazonais (SARIMA), para comparar seu desempenho. Foi empregada uma metodologia quantitativa de natureza descritiva e explicativa, utilizando 288 observações mensais de janeiro de 2023 a dezembro de 2025. Ambos os modelos foram ajustados utilizando o software estatístico SAS®, e seu desempenho foi comparado com base no erro quadrático médio fora da amostra (RECM) (janeiro de 2023 a dezembro de 2025), bem como nos critérios de informação de Akaike (AIC) e de Schwarz (SBC). Nos resultados, o modelo SARIMA (2,1,0)(0,1,1)[12] apresentou um RECM menor, coeficientes estatisticamente significativos e valores de AIC e SBC menores, superando o modelo UCM. A análise se limita a uma série temporal específica do IPC mexicano, portanto, sua aplicação a outros contextos requer cautela. A sensibilidade do UCM a mudanças estruturais oferece uma vantagem em cenários com alta volatilidade. Em conclusão, o modelo SARIMA demonstrou melhor capacidade preditiva e ajuste aos dados em comparação ao modelo UCM, sugerindo que ele é uma ferramenta eficaz para a análise prospectiva do comportamento inflacionário no México e para a tomada de decisões de políticas públicas.

Palavras-chave: Box-Jenkins SARIMA, economia, inflação, modelos de séries temporais.

Fecha Recepción: Enero 2026

Fecha Aceptación: Mayo 2026

Introducción

El Índice Nacional de Precios al Consumidor (INPC) es el referente rector para evaluar la evolución del nivel de precios de una canasta de bienes y servicios, ponderada según su relevancia económica, y constituye el principal indicador para evaluar la inflación. Con base en el periodo de julio de 2018=100, su elaboración incluye la recolección quincenal de más de 159 mil precios en 55 ciudades del país, abarcando 299 conceptos genéricos distribuidos en 91 sectores que conforman la estructura económica nacional. La recopilación de datos se realiza una o dos veces por quincena, dependiendo del producto (Heath, 2012; Salas, 2021; Alonso y Rivera, 2017; Banco de México [BANXICO], 2025; Instituto Nacional de Estadística y Geografía [INEGI], 2025a).

El enfoque clásico de series cronológicas descompone una serie temporal y_t en: tendencia, estacionalidad, ciclo e irregular ($y_t = T_t + S_t + C_t + I$), donde esta elección de desagregación radica en que facilita separar los efectos visibles de los que permanecen ocultos en el comportamiento de la variable analizada. No obstante, Harvey (1989) propuso un modelo más completo mediante componentes no observables (UCM-por sus siglas en inglés), donde y_t es la suma de elementos estructurales (μ_t = tendencia, γ_t = estacionalidad, ψ_t = ciclo, r_t = autorregresivo, $\sum_{i=1}^p \phi_i y_{t-i}$ = variable rezagada, $\sum_{j=1}^m \beta_j x_{jt}$ = variable explicativa y ε_t = perturbación aleatoria).

El método estructurado Box-Jenkins comprende cuatro fases: identificación, estimación, validación y aplicación del modelo, fundamentándose en valores pasados de la serie para construir modelos que combinan elementos autorregresivos, términos de diferenciación y media móvil (ARIMA-por sus siglas en inglés). Estos modelos requieren que la serie sea estacionaria, es decir, con media, varianza y covarianza constantes. Para ello, se aplican transformaciones que estabilizan la varianza (Guerrero, 2009) y diferencias que estabilizan el nivel, guiadas por los análisis de autocorrelación (FAC) y autocorrelación parcial (FACP) (Gujarati y Porter, 2010).

La precisión de un modelo de pronóstico se evalúa mediante métricas como el error medio (ME), el error absoluto medio (MAE), el error porcentual medio (MPE), el error porcentual absoluto medio (MAPE) y el error cuadrático medio (MSE). A menor valor de estas medidas, mayor exactitud del modelo predictivo (Farrera, 2013).

Para evaluar estos modelos, en la literatura reciente diversos estudios han aplicado modelos de series de tiempo para el pronóstico de variables macroeconómicas, particularmente en contextos inflacionarios. Los modelos SARIMA han demostrado alta capacidad predictiva en economías emergentes al capturar patrones estacionales y dinámicas de corto plazo, siendo ampliamente utilizados para el análisis de inflación, tipo de cambio y crecimiento económico (Hyndman & Athanasopoulos, 2021). En el caso de México, Flores (2017) evidencia que los modelos estacionales mejoran significativamente la precisión en horizontes de corto plazo.

Por otra parte, los modelos estructurales de componentes no observables (UCM) han sido empleados para descomponer series económicas en tendencia, ciclo y estacionalidad, permitiendo una interpretación más profunda del comportamiento macroeconómico (Durbin & Koopman, 2012; Ercolani, 2023). Su aplicación ha sido

relevante en el análisis de inflación subyacente y en la identificación de choques estructurales (Sujata, 2010; Brintha *et al.*, 2014).

No obstante, la evidencia empírica sugiere que existe una dualidad entre capacidad predictiva e interpretación estructural, donde los modelos SARIMA tienden a optimizar el pronóstico, mientras que los modelos UCM aportan mayor comprensión del comportamiento económico subyacente. Esta brecha justifica la comparación metodológica planteada en la presente investigación. Sin embargo, enfoques híbridos (Makridakis *et al.*, 2022) han mostrado mejoras significativas al emplear técnicas de machine learning (Hewamalage *et al.*, 2021).

A pesar de ello, puede persistir la sobreestimación, la cual puede atribuirse a la presencia de choques estructurales recientes en la economía, particularmente asociados a presiones inflacionarias post-pandemia, ajustes en la política monetaria y interrupciones en cadenas de suministro (FMI, 2023). Dado que ambos enfoques corresponden a modelos univariados, su capacidad para incorporar cambios abruptos en variables exógenas es limitada, lo que puede inducir sesgos sistemáticos en el horizonte de proyección. En este sentido, la sobreestimación observada no representa una deficiencia metodológica, sino una evidencia empírica de las restricciones inherentes a este tipo de modelos (Duran *et al.*, 2012).

El trabajo de investigación tuvo como objetivo predecir el Índice Nacional de Precios al Consumidor empleando dos enfoques de series de tiempo: componentes no observables (UCM) y el modelo estacional autorregresivo integrado de media móvil (SARIMA) para contrastar su desempeño. Bajo el criterio de parsimonia, se planteó que, al comparar ambos métodos, el modelo estructural UCM presentaría una configuración de componentes equivalente a la del modelo SARIMA, además de que su descomposición reflejaría de manera clara los periodos de estabilidad o variabilidad presentes en la serie analizada.

Materiales y métodos

Se recurrió a una serie histórica de datos acumulados del INPC, que abarcó de enero de 2002 a diciembre de 2025 (INEGI, 2025b). Se aplicó una transformación logarítmica a la serie para evitar problemas de unidades o magnitudes (Sabau, 2011) y facilitar la comparación entre modelos.

Modelo UCM

Se desarrolló la configuración básica del modelo estructural (BSM, por sus siglas en inglés), en referencia a Pelagatti (2016) donde, con ajustes metodológicos propios, la ecuación estimada es:

$$y_t = \mu_t + \gamma_t + \psi_t + \varepsilon_t \quad (1)$$

Donde:

$$\mu_t = \mu_{t-1} + \beta_t + \eta_t \quad (1.1)$$

$$\beta_t = \beta_{t-1} + \xi_t$$

En el modelo estructural, y_t corresponde al conjunto de datos temporales que se estudia y para el cual se estiman proyecciones, μ_t es el elemento de tendencia (μ_0 nivel, β_t pendiente, η_t ruido blanco con varianza σ_η^2 , ξ_t ruido blanco con varianza σ_ξ^2), γ_t elemento estacional, ψ_t elemento de ciclo, ε_t elemento irregular. Según Sabau (2011), los ciclos con periodicidades distintas a la estacional se modelan mediante razones trigonométricas como el seno y el coseno. Fomby (2008) propuso una formulación del elemento cíclico que se presenta a continuación:

$$\psi_t = \cos\lambda\psi_{t-1} + \sin\lambda\psi_{t-1}^* + v_t \quad (1.2)$$

$$\psi_t = -\sin\lambda\psi_{t-1} + \cos\lambda\psi_{t-1}^* + v_t^*$$

Las funciones trigonométricas básicas seno y coseno permiten representar el elemento cíclico, en el cual v_t y v_t^* son perturbaciones aleatorias no correlacionadas entre sí ni con otros elementos, y comparten una misma varianza σ_v^2 . La frecuencia λ , expresada en radianes, indica cuántas veces se repite el ciclo en un periodo de 2π , por lo que el ciclo tiene una duración de $2\pi/\lambda$. Según Vidal y Fundora (2004), complementando a Harvey (1989) y Fomby (2008), para capturar ciclos falsos típicos que caracterizan series económicas, se incorpora un factor de amortiguación ρ , que otorga mayor flexibilidad a la dinámica cíclica del modelo:

$$\psi_t = \rho\cos\lambda\psi_{t-1} + \rho\sin\lambda\psi_{t-1}^* + v_t \quad (1.3)$$

$$\psi_t = \rho\sin\lambda\psi_{t-1} + \rho\cos\lambda\psi_{t-1}^* + v_t^*$$

Derivado del análisis anterior, el ciclo se define como estacionario siempre que $|\rho| < 1$.

Para el elemento estacional:

$$\sum_{i=0}^{s-1} \gamma_{t-i} = \omega_t \quad (1.4)$$

La acumulación de los impactos derivados de los efectos estacionales (ω_t) asume media cero, sin embargo, su evolución depende de la varianza σ_ω^2 : si esta es pequeña, los

efectos estacionales cambian lentamente; si es grande, se disipan rápidamente. Cuando $\sigma_{\omega}^2 = 0$, las fluctuaciones estacionales permanecen constantes y no muestran cambios a lo largo del periodo analizado (Fomby, 2008). Según Vidal y Fundora (2004), se recomienda un enfoque determinista cuando hay pocos años de datos y no se puede establecer un patrón estacional; en cambio, si la estacionalidad varía con el tiempo, se modela como estocástica, implicando $\sigma_{\omega}^2 \neq 0$.

Modelo SARIMA

El modelo SARIMA, derivado de ARIMA, incorpora elementos estacionales en la estructura de series de tiempo (Box *et al.*, 2008). Esta metodología predice valores presentes y futuros de una variable con base en promedios ponderados de sus propios valores históricos. La especificación del modelo incluye elementos no estacionales (p, d, q) y estacionales (P, D, Q), permitiendo capturar tanto patrones a corto como a largo plazo en la serie Y_t :

$$\phi(B)\Phi(B^s)(1-B)^d(1-B^s)^DY_t = \theta(B)\Theta(B^s)e_t \quad (2)$$

Por su parte, en el modelo SARIMA se dividen en elementos no estacionales y estacionales: $\phi(B)$ y $\Phi(B^s)$ representan los operadores autorregresivos de órdenes p y P, mientras que $\theta(B)$ y $\Theta(B^s)$ corresponden a los operadores de media móvil de órdenes q y Q. Las diferencias no estacionales y estacionales de órdenes d y D respectivamente, se aplican mediante operadores $(1-B)^d$ y $(1-B^s)^D$, siendo s la periodicidad estacional. Mientras, la perturbación aleatoria e_t , usualmente denominado ruido blanco. La selección del modelo se basa en análisis gráfico de los residuales (correlogramas) buscando aleatoriedad y ausencia de patrones. Se adoptó un enfoque parsimonioso, evaluando la bondad de ajuste mediante los criterios de información de Akaike (AIC) y Schwarz (SBC), cuya minimización guía la elección óptima del modelo a través de distintas combinaciones de órdenes autorregresivos y de media móvil. En modelos ARIMA, la estacionariedad de la serie es esencial y se verifica mediante la prueba Dickey-Fuller Aumentada (ADF), la cual contrasta la hipótesis nula de presencia de raíz unitaria $H_0: \varphi = 0$ frente a la alternativa de estacionariedad débil $H_a: \varphi < 0$. La prueba se fortalece al incluir diferencias adicionales hasta un orden razonable. La formulación deriva de la reescritura de un modelo autorregresivo, donde φ se define como $\varphi = \alpha - 1$ (Dickey & Fuller, 1981).

Resultados

Modelo UCM

Se evaluaron seis configuraciones del modelo UCM, con diferentes supuestos fijos o aleatorios sobre nivel, pendiente, estacionalidad y ciclos. La selección óptima se basó en criterios de información de Akaike (AIC) y Schwarz (SBC) (Tabla 1).

Tabla 1. Implementación de modelos UCM para ajustar los elementos del INPC.

Modelo	Descripción	Elementos de varianza	AIC ^b	SBC ^a
UCM 1	Nivel aleatorio	$\sigma_n^2 > 0$	-1888	-1874
	Pendiente aleatoria	$\sigma_\xi^2 > 0$		
	Estacionalidad aleatoria	$\sigma_\omega^2 > 0$		
UCM 2	Nivel aleatorio	$\sigma_n^2 > 0$	-1890	-1880
	Pendiente fija	$\sigma_\xi^2 = 0$		
	Estacionalidad aleatoria	$\sigma_\omega^2 > 0$		
UCM 3	Nivel fijo	$\sigma_n^2 = 0$	-1836	-1829
	Pendiente aleatoria	$\sigma_\xi^2 > 0$		
	Estacionalidad fija	$\sigma_\omega^2 = 0$		
UCM 4	Nivel fijo	$\sigma_n^2 = 0$	-1901	-1885
	Pendiente aleatoria	$\sigma_\xi^2 > 0$		
	Estacionalidad fija	$\sigma_\omega^2 = 0$		
	Un ciclo aleatorio	$\sigma_v^2 > 0$		
UCM 5	Nivel fijo	$\sigma_n^2 = 0$	-1895	-1869
	Pendiente aleatoria	$\sigma_\xi^2 > 0$		
	Estacionalidad fija	$\sigma_\omega^2 = 0$		
	Dos ciclos aleatorios	$\sigma_v^2 > 0, \sigma_v^2 > 0$		
UCM 6	Nivel fijo	$\sigma_n^2 = 0$	-1832	-1818
	Pendiente aleatoria	$\sigma_\xi^2 > 0$		
	Estacionalidad fija	$\sigma_\omega^2 = 0$		
	Ciclo fijo	$\sigma_v^2 = 0$		

^aSBC= criterio de información de Schwartz, ^bAIC: criterio de información de Akaike.

El modelo cuatro resultó ser el adecuado en relación con la evaluación de la hipótesis correspondiente, además de analizar las estimaciones de los parámetros, valores t y niveles de significancia, con base en la hipótesis nula (H_0): el elemento no es aleatorio, frente a la alternativa (H_a): el elemento es aleatorio. A partir de estos resultados (Tabla 2), es posible determinar si el modelo presenta un comportamiento determinista o estocástico.

Tabla 2. Valores estimados de los criterios.

Elemento	Parámetro	Estimador	Error Estándar	Valor t	Aprox Pr > t
Irregular	Varianza del error	2.11E-12	1.87E-13	11.26	<.0001
Pendiente	Varianza del error	0.0000054	2.21E-06	2.45	0.0145
Ciclo	Factor de amortiguación	0.82097	0.03007	27.3	<.0001
Ciclo	Periodo	10.45319	1.02806	10.17	<.0001
Ciclo	Varianza del error	0.00000204	3.85E-07	5.3	<.0001

Fuente: construcción propia con datos procesados en el software SAS®.

Las estimaciones de los parámetros (Tabla 2) basadas en pruebas de significancia individual, permiten determinar la pertinencia de cada elemento en el modelo. El análisis mostró que todos los elementos son relevantes, excepto el irregular, que inicialmente no resultó significativo (Tabla 3). No obstante, este último se mantuvo en la especificación al constituir parte inherente del proceso aleatorio propio del modelo y absorber fluctuaciones no sistemáticas.


Tabla 3. Significancia individual de cada elemento.

Elemento	DF	Chi-cuadrado	Pr > ChiSq
Irregular	1	0.01	0.9996
Nivel	1	202535	<.0001
Coeficiente angular	1	14.87	0.0001
Ciclo	2	6.44	0.04
Estacionalidad	11	365.36	<.0001

Fuente: construcción propia con datos procesados en el software SAS®.

La evaluación de los residuales confirma que éstos respetan los supuestos de ruido blanco, al no mostrar correlación ni patrones sistemáticos y presentar una distribución aproximadamente normal, validada mediante análisis gráfico (histograma, gráfico Q-Q) y funciones ACF y PACF. De igual manera, el modelo no presentó autocorrelación en las gráficas de ACF y PACF, con distintos rezagos (Figura 1).

Figura 1. Valoración del ajuste con relación al modelo.



Nota: UCM: A) histograma de residuales, B) esquema de cuantiles (Q-Q) de residuos, C) ACF de residuales y D) PACF de residuales. Fuente: construcción propia.

El modelo estimado incorporó una tendencia integrada por un nivel determinístico y una pendiente estocástica, una estacionalidad determinística, un ciclo estocástico y un elemento irregular también estocástico. La ecuación general fue $y_t = \mu_t + \gamma_t + \psi_t + \varepsilon_t$, donde la tendencia (μ_t) estuvo formada por un nivel constante y una pendiente aleatoria. Dado que la pendiente estocástica $\sigma_\eta^2 > 0$ y nivel no estocástico $\sigma_\xi^2 = 0$, el modelo se clasificó como de tendencia alisada, es decir, la variabilidad provino de cambios en la dinámica de la tasa de crecimiento de largo plazo, no del nivel. Esta configuración reflejó que el INPC mostró un crecimiento tendencial que evoluciona de manera continua en el tiempo. El elemento cíclico presentó un comportamiento aleatorio e irregular, lo que implicó que los ciclos económicos del INPC no siguen una periodicidad fija y se manifiestan como oscilaciones recurrentes no sistemáticas.

Modelo SARIMA

En esta investigación, se implementaron métodos de modelación correspondientes a procesos temporales, considerando distintos órdenes. Para validar su aplicabilidad, se evaluó la estacionariedad (media y varianza constantes) de la serie mediante la prueba Dickey-Fuller Aumentada (ADF), contrastando la hipótesis nula de presencia de raíz unitaria frente a la alternativa de estacionariedad, rechazando la primera cuando el estadístico tau fue menor o igual al valor crítico (tau calculado $\leq$ tau de tablas). Al detectar no estacionariedad, se aplicaron diferenciaciones: una de tipo ordinaria ($d=1$) y otra

estacional ($D=1$), debido a la existencia de patrones recurrentes cada 6, 12 y 24 observaciones. Tras estas transformaciones, el valor de tau permitió rechazar la hipótesis nula, concluyéndose que la serie del INPC se volvió estacionaria, es decir, con comportamiento estable a lo largo del tiempo (Tabla 4).


Tabla 4. Test Dickey Fuller Aumentada (ADF), serie INPC.

Tipo	Retardos	Tau	Pr < Tau	F	Pr > F
Media simple	0	-11.77	<.0001	69.27	0.001
	1	-10.97	<.0001	60.19	0.001
	2	-9.39	<.0001	44.12	0.001
Tendencia	0	-11.95	<.0001	69.02	0.001
	1	-10.95	<.0001	59.98	0.001
	2	-9.38	<.0001	43.96	0.001

Fuente: construcción propia

Los indicadores que permitieron identificar la estructura temporal, mediante autocorrelaciones simples y parciales (ACF y PACF) de la serie diferenciada ($d=12$, $D=12$), evidenciaron un patrón estacional recurrente cada 12 periodos ($s=12$). El análisis ADF en los rezagos 1, 3 y 12 confirmó dicho comportamiento, identificándose una estructura autorregresiva (AR) y de media móvil (MA) en los rezagos 12 y 24. Este proceder sustentó la elección de un modelo SARIMA para describir la dinámica del indicador económico INPC (Figura 2).

Figura 2. Autocorrelograma simple y parcial para INPC $Y_t = (1 - B)^d(1 - B^s)^D$



Nota: A) ACF, B) PACF. Fuente: construcción propia.

En el procedimiento de especificación del modelo, se analizaron las funciones ACF y PACF para obtener un diagnóstico gráfico del comportamiento de la serie, identificando únicamente tres rezagos estadísticamente significativos según las pruebas de

ruido blanco. Se estimaron diversas combinaciones de términos AR y MA (p, q), así como sus elementos estacionales SAR y SMA (P, Q), evaluando el ajuste mediante selección y criterios de información AIC y SBC. El modelo con mejor desempeño fue SARIMA(2,1,0)(0,1,1)_{s=12}, según se revela en Tabla 5.


Tabla 5. Cálculo de los mejores modelos SARIMA identificados.

SARIMA [†]	Parte ordinal		Parte estacional		SBC [¶]	AIC ^p
	AR [§] (p)	MA [□] (q)	AR ^{§§} (P)	MA ^{□□} (Q)		
(2,1,0)X(0,1,1) _{s=12}	0.40245	.	.	0.85100	-2510.8	-2521.7
(1,1,0)X(2,0,0) _{s=12}	0.44757	.	0.36204	.	-2556.1	-2567.1
(1,1,0)X(0,1,1) _{s=12}	0.36676	.	.	0.85187	-2513.9	-2521.1

[†]SARIMA: estacional autorregresivo integrado de media móvil, [§]AR: autorregresivo de orden (p), [□]MA: media móvil de orden (q), ^{§§}AR: autorregresivo estacional de orden (P), ^{□□}MA: media móvil estacional de orden (Q), [¶]SBC= criterio de información de Schwartz, ^pAIC: criterio de información de Akaike. Fuente: construcción propia con datos procesados en el software SAS®.

Con los valores de los parámetros ya estimados, se aceptó el modelo SARIMA(2,1,0)X(0,1,1)_{s=12} mediante el análisis de residuos. Los resultados confirmaron que estos son ruido blanco, es decir, carecen de correlación, siguen una distribución aproximadamente normal y no presentan patrones detectables (son completamente aleatorios y no conservan dependencia temporal entre observaciones). La normalidad se evidenció en los gráficos de histograma y Q-Q, mientras que la ausencia de autocorrelación se verificó con las funciones ACF y PACF dentro de la banda de confianza (Figura 3).

Figura 3. Análisis de residuales, calibración del modelo SARIMA(2,1,0)X(0,1,1)_{s=12}.



Nota: A) histograma B) esquema de cuantiles (Q-Q), C) ACF, D) PACF, E) autocorrelograma inverso de errores, F) ruido blanco en residuos. Fuente: elaboración propia.

Conforme a la metodología de Box-Jenkins y los criterios de significancia estadística, se consideraron relevantes los coeficientes cuyo estadístico t, en valor absoluto, excedió el umbral de dos y cuyos *p-valores* fueron menores a 0.05. Siendo así, el enfoque SARIMA(2,1,0)(0,1,1)_{s=12} se identificó como el más adecuado en comparación con las demás alternativas evaluadas (Tabla 6).

Tabla 6. Estimación del modelo mediante máxima verosimilitud, para la serie del INPC

Parámetro	Estimador	Error estándar	Valor t	Aprox Pr > t	Retardo
MA1,1	0.85100	0.04261	19.97	<.0001	12
AR1,1	0.40245	0.05890	6.83	<.0001	1
AR1,2	-0.09636	0.05876	-1.64	0.0215	2

Fuente: construcción propia con datos procesados en el software SAS®.


Para evaluar la etapa de implementación del modelo, se recurrió al estimador del Error Cuadrático Medio (ECM), considerado un criterio clave de optimalidad. Sin embargo, la calidad predictiva dependió en gran medida de la persistencia de los comportamientos observados en el pasado, de modo que la presencia de cambios súbitos afectó negativamente la significancia de los resultados.

Evaluación predictiva del modelo fuera de muestra

Se comparó el desempeño predictivo del UCM y del SARIMA mediante 36 observaciones fuera de muestra (enero 2023–diciembre 2025). El SARIMA presentó el menor error cuadrático medio ($RECM=0.2951$), superando al UCM ($RECM=0.3207$). A pesar de ello, ambos modelos tendieron a sobreestimar el INPC hacia el final del horizonte proyectado, especialmente a partir del tercer trimestre de 2024 y durante 2025, en respuesta a variaciones no capturadas por la especificación univariada (Figura 4).

Ambos modelos reprodujeron adecuadamente la trayectoria del INPC y permitieron caracterizar su comportamiento en el periodo analizado. No obstante, las diferencias observadas en el desempeño dentro y fuera de muestra evidenciaron que la capacidad predictiva y la interpretación estructural no necesariamente convergen en un mismo enfoque, ya que el SARIMA optimizó la precisión proyectiva mientras que el UCM aportó elementos para descomponer la dinámica del índice. En suma, los resultados confirman que los modelos comparados cumplen funciones distintas: uno optimiza la predicción y el otro la comprensión de la estructura. Esta dualidad resulta clave para interpretar sus alcances y limitaciones.

Figura 4. Desempeño predictivo del INPC fuera de muestra: enero 2023-diciembre 2025.



Fuente: construcción propia.

Los resultados evidenciaron que la estructura del INPC presentó una estacionalidad bien definida y estable a lo largo del periodo analizado, lo que favoreció la parsimonia del modelo SARIMA y mostró mayor precisión predictiva. Aunque ambos enfoques capturaron adecuadamente la variabilidad de la serie, el SARIMA mostró menores discrepancias entre los valores observados y los pronosticados, lo que sugirió que, bajo condiciones de estacionalidad determinista, los procesos Box-Jenkins constituyen una alternativa eficiente para el pronóstico de corto plazo. Por su parte, el UCM resultó útil para descomponer el comportamiento inflacionario e identificar la naturaleza transitoria de ciertos movimientos cíclicos, aportando una interpretación estructural que complementa el análisis, pero con menor capacidad para anticipar la evolución futura del índice.

Discusión

El modelo $SARIMA(2,1,0) \times (0,1,1)_{s=12}$ mostró mejor desempeño predictivo que el UCM, lo cual coincide con estudios recientes que destacan la eficacia de enfoques estacionales para pronosticar inflación en economías emergentes. En México, diversos trabajos han documentado que los modelos SARIMA capturan adecuadamente la dinámica inflacionaria de corto plazo, compitiendo frente a metodologías estructurales o multivariadas

(Ayllon *et al.*, 2024). Estos resultados son consistentes con la evidencia previa que señala que los procesos Box-Jenkins tienden a mejorar su precisión cuando la estacionalidad es determinista y estable. Asimismo, cuando la serie cumple criterios de estacionariedad evaluados mediante pruebas ADF (Pankratz, 1983; Enders, 2014).

Por su parte, el UCM permitió descomponer el INPC en elementos permanentes y transitorios, lo cual es congruente con la literatura que utiliza este enfoque para analizar choques cíclicos y efectos estacionales (Ercolani, 2023; Sujata, 2010). La inclusión del componente irregular resulta metodológicamente adecuada, dado que absorbe fluctuaciones aleatorias sin dirección sistemática, por lo que su exclusión podría sesgar la estructura del modelo (Brintha *et al.*, 2014). La presencia de ciclos irregulares en el INPC es coherente con el entendimiento económico de los ciclos como oscilaciones recurrentes, aunque no necesariamente periódicas, resultado ampliamente discutido en la teoría macroeconómica (Mankiw, 2012).

Si bien el UCM aportó una mejor caracterización estructural de la serie al identificar elementos transitorios y permanentes, su menor precisión predictiva sugiere que la descomposición estructural no necesariamente optimiza el pronóstico cuando la finalidad es predictiva. Este hallazgo es consistente con trabajos que han señalado que la estabilidad del patrón histórico es un determinante clave del desempeño en modelos de series de tiempo (Luis *et al.*, 2019). En particular, la literatura mexicana también ha documentado que los esquemas estacionales deterministas tienden a mejorar los errores cuadráticos medios en horizontes fuera de muestra, reforzando los resultados del presente estudio (Flores, 2017).

Ambos modelos presentaron sobreestimación hacia el final del horizonte analizado, fenómeno asociado a choques externos, ajustes de política monetaria y volatilidad pospandemia en países emergentes (BANXICO, 2022; OCDE, 2023). Entre las limitaciones del estudio destaca el uso de un enfoque univariado sin incorporar variables determinantes como tipo de cambio, precios energéticos o actividad económica, variables reconocidas como relevantes para explicar la inflación mexicana y latinoamericana (De Gregorio, 2019; Bonizzi *et al.*, 2022). No obstante, los resultados contribuyen metodológicamente para el análisis aplicado en el ámbito nacional e internacional.

Estudios recientes han comenzado a explorar enfoques híbridos que combinan modelos SARIMA con técnicas de aprendizaje automático, logrando mejoras significativas en la precisión predictiva en contextos inflacionarios complejos (Peirano *et al.*, 2021). Estos

avances sugieren que la integración de metodologías tradicionales y modernas representa una línea prometedora para el análisis económico aplicado.

Conclusiones

Dentro del enfoque de elementos no observables, las variaciones asociadas al patrón tendencial se explican principalmente por modificaciones en la pendiente y no por cambios en el nivel, reflejando un crecimiento sostenido y constante a lo largo del periodo analizado. Por su parte, el modelo estacional autorregresivo integrado de media móvil permitió ajustar adecuadamente la dinámica de una serie temporal, ya sea estable o con fluctuaciones, empleando diferenciación simple y términos autorregresivos para capturar tendencias determinísticas o estocásticas. El proceso SARIMA(2,1,0)×(0,1,1)_{s=12} ofreció la representación más adecuada dentro del conjunto evaluado. Su desempeño predictivo resultó satisfactorio, con un margen de error fuera de muestra inferior al 30%. En conjunto, la estimación de parámetros y los pronósticos obtenidos siguiendo el principio de simplicidad o parsimonia y considerando la evolución histórica de la serie proporcionan información útil para tomadores de decisiones económicas estratégicas, sustentada en información que explica de forma eficiente y estadística la complejidad de un fenómeno que monitorea los cambios en el nivel de gasto necesario para que los hogares mantengan su bienestar en un país. Este estudio contribuye a la literatura empírica al comparar dos enfoques metodológicos ampliamente utilizados en el análisis de series de tiempo, proporcionando evidencia aplicada para el caso mexicano con información reciente. La diferenciación entre capacidad predictiva y descomposición estructural constituye un aporte relevante para la toma de decisiones en política económica.

Futuras líneas de investigación

Con base en los hallazgos y limitaciones del presente estudio, se proponen diversas líneas para investigaciones futuras orientadas a fortalecer el análisis y la capacidad predictiva de los modelos de inflación. En primer lugar, resulta pertinente la incorporación de variables exógenas mediante el desarrollo de modelos multivariados que integren determinantes clave de la inflación mexicana, como el tipo de cambio, las tasas de interés, los precios de energéticos y la actividad económica, con el fin de mejorar la precisión en horizontes de mediano y largo plazo. Asimismo, se sugiere explorar modelos híbridos y no lineales que combinen enfoques SARIMA con técnicas de aprendizaje automático, como

redes neuronales o modelos de cambio de régimen, capaces de capturar patrones complejos y cambios estructurales en la dinámica inflacionaria. De igual forma, es recomendable realizar análisis desagregados del INPC, diferenciando entre componentes subyacentes y no subyacentes, para identificar fuentes específicas de presión inflacionaria y perfeccionar los pronósticos. También se plantea la necesidad de validar los modelos en horizontes temporales más amplios que incluyan ciclos económicos completos y episodios de alta volatilidad, como crisis financieras o pandemias, con el propósito de evaluar su robustez en contextos de incertidumbre. Finalmente, se propone incorporar escenarios de política monetaria mediante simulaciones que permitan analizar la sensibilidad de los pronósticos ante distintos regímenes y estrategias del banco central.

Referencias

- Alonso, J. C. y Rivera, A. F. (2017). Pronosticando la inflación mensual en Colombia un paso hacia delante: una aproximación “de abajo hacia arriba”. *Revista de Métodos Cuantitativos para la Economía y la Empresa*, 23, 98-118.
- Ayllon, B. J. C., Omaña, S. J. M., Matus, G. J. A., Martínez, D. M. Á., Sangerman, J. D. M. y González, R. F. (2024). Análisis de intervención en la variación porcentual del INPC en México, enero 2002- junio 2020. *Economía Sociedad y Territorio*, 24(74), 1-18.
- Banco de México (BANXICO). (2025). Principales elementos del cambio de base del INPC. Extracto del Informe Trimestral abril - junio 2018. pp. 55-56.
- Banco de México (BANXICO). (2022). Informe trimestral enero-marzo 2022. Banco de México. <https://www.banxico.org.mx>.
- Bonizzi, B., Kaltenbrunner, A. & Powell, J. (2022). Financialised capitalism and the subordination of emerging capitalist economies, *Cambridge Journal of Economics*, 46(4), 651-678.
- Brintha, N. K. K., Samita, S., Abeynayake, N. R., Idirisinghe, I. M. S. K., & Kumarathunga, A. M. D. P. (2014). Use of Unobserved Components Model for forecasting non-stationary time series: A case of annual national coconut production in Sri Lanka. *Sri Lankan Journal of Applied Statistics*, 25, 423-431.
- Box, G. E., Jenkins, G. M. and Reinsel, G. C. (2008). *Time series analysis: Forecasting and control*. (4th ed.). John Wiley & Sons.

- De Gregorio, J. (2019). Inflation Targets in Latin America. *Peterson Institute for International Economics*, 19, 1-16.
- Dickey, D. A. & Fuller, W. A. (1981). Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica*, 49(4), 1057-1072.
- Duran, R., Garrido, E., Godoy, C. y de Dios, T. J. (2012). Inflation prediction in Mexico with models disaggregated by components. *Estudios Económicos De El Colegio De México*, 27(1), 133-167.
- Durbin, J., and Koopman, S. J. (2012). *Time series analysis by state space methods* (2nd ed.). Oxford University Press. 343 p.
- Enders, W. (2014). *Applied econometrics*. (4th ed.). John Wiley & Sons.
- Ercolani, J. (2023). Unobserved Components Models. In Hamilton, J. H., Dixit, A., Edwards, S. and Judd, K. (Eds.), *Oxford Research Encyclopedias: Economics and Finance* Oxford University Press.
<https://doi.org/10.1093/acrefore/9780190625979.013.896>.
- Farrera, G. A. (2013). *Manual de pronósticos para la toma de decisiones*. (1a. ed.). Editorial Digital Tecnológico de Monterrey.
- Flores, C. L. (2017). Pronóstico del Índice Nacional de Precios al Consumidor. *Revista Iberoamericana de Contaduría, Economía y Administración*, 6(12), 60-88.
<https://doi.org/10.23913/ricea.v6i12.95>
- Fomby, T. (2008). The unobservable components model. SAS Help Documentation, Southern Methodist University.
- Gujarati, D. y Porter, D. (2010). *Econometría*. (5a. ed.). McGraw-Hill.
- Guerrero, G. V. M. (2009). *Análisis estadístico y pronóstico de series de tiempo económicas*. (3ra. ed.). Jit Press.
- Heath, J. (2012). Lo que indican los indicadores: Cómo utilizar la información estadística para entender la realidad económica de México. INEGI.
- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent neural networks for time series forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1): 388-427. <https://doi.org/10.1016/j.ijforecast.2020.06.008>
- Harvey, A. C. (1989). Forecasting, structural time series models and the Kalman filter. Cambridge University Press.
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. 291 p. <https://otexts.com/fpp3/>

- INEGI. (2025a). Índice Nacional de Precios al Consumidor (INPC). Base de datos de consulta pública. En: <https://www.inegi.org.mx/temas/inpc/>
- INEGI. (2025b). Índice Nacional de Precios al Consumidor (INPC). Documento metodológico. Base segunda quincena de julio 2018. 137 p.
- FMI. (2023). International Monetary Fund. *World Economic Outlook: Inflation and disinflation*. IMF Publications. 161 p. <https://www.imf.org/-/media/files/publications/weo/2023/october/english/text.pdf>
- Luis, R. S., García, R. C., García, R., Arana, O. A. y González, A. (2019). Metodología Box-Jenkins para pronosticar los precios de huevo blanco pagados al productor en México. *Agrociencias*, 53, 911-925.
- Mankiw, N. G. (2012). *Principios de Economía*. (6a. ed.). Cengage Learning.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2022). The M5 competition: Background, organization, and implementation. *International Journal of Forecasting*. 38(4): 1325-1336. <https://doi.org/10.1016/j.ijforecast.2021.07.007>
- OCDE (Organization for Economic Co-operation and Development). (2023). OCDE Economic Outlook, Volume 2023 Issue 1: A long unwinding road, OCDE Publishing, Paris, 247 p. <https://doi.org/10.1787/ce188438-en>.
- Pankratz, A. (1983). *Forecasting with univariate Box-Jenkins models: Concepts and cases*. John Wiley & Sons.
- Peirano, R., Werner, K. and Minutolo, M. (2021). Forecasting Inflation in Latin American Countries Using a SARIMA-LSTM Combination, PREPRINT (Version 1) available at Research Square. <https://doi.org/10.21203/rs.3.rs-607554/v1>.
- Pelagatti, M. M. (2016). *Time series modelling with unobserved components*. (1st ed.). Chapman & Hall/CRC Press.
- Sabau, G. H. (2011). *Análisis econométrico dinámico: Una exploración para series de tiempo con el método econométrico*. (1a. ed.). Universidad Iberoamericana.
- Salas, J. (2021). Inflación: El cálculo estadístico de una enfermedad social. In: Heath, J. (coord.). Lo que indican los indicadores: Cómo utilizar la información estadística para entender la realidad económica de México. INEGI. pp. 85-100.
- Sujata, K. (2010). UCM: A measure of core inflation. *International Journal of Monetary Economics and Finance*, 3(3), 248-269. <https://doi.org/10.1504/IJMEF.2010.033456>.

Vidal, A. P. y Fundora, F. A. (2004). Tendencias y ciclos en el Producto Interno Bruto de Cuba. Estimación de un modelo estructural univariante de series temporales. 42 Aniversario de los Estudios de Economía en la Universidad de La Habana.