

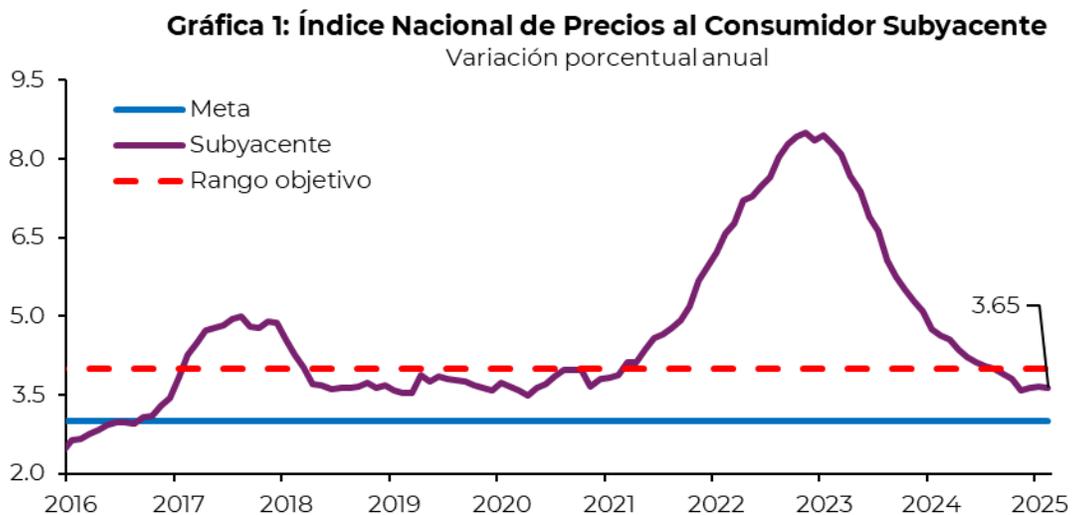
# Distribución de la inflación subyacente condicionada a sus determinantes, siguiendo una curva de Phillips Neokeynesiana.

## ***Evolución y pronóstico en México (2023-2025)***

*Luis Armando García Rodríguez*

### **Introducción.**

A febrero de 2025, la inflación subyacente continúa una trayectoria descendiente tras haber alcanzado un máximo anual de 8.51% en noviembre de 2022, actualmente se encuentra por debajo del 4%, dentro del rango objetivo del Banco de México, y acercándose a la meta inflacionaria de largo plazo de 3%.



Nota: E datos del lado derecho corresponde a los valores en febrero de 2025  
Fuente: Elaboración propia con datos de Banco de México

Dada la operación con rezagos de la política monetaria, la identificación de la trayectoria de la inflación subyacente es crucial para las decisiones prospectivas de política monetaria. Este ensayo se propone analizar y pronosticar dicha trayectoria a través de su distribución condicionada a sus determinantes, siguiendo una curva de Phillips neokeynesiana.

Para ello, se emplean regresiones cuantílicas, las cuales permitirán estimar los percentiles 10, 50 y 90 de la distribución condicional de la inflación en cada momento  $t$ . Posteriormente, se asume que la inflación subyacente sigue una distribución normal-sesgada; y a partir de los percentiles estimados, se calculan los parámetros de localización, escala y asimetría de la distribución condicionada en cada momento  $t$ , empleando el algoritmo iterativo de Nelder-Mead.

## Metodología

La regresión cuantílica es un método de estimación que permite modelar los cuantiles de la distribución condicional de una variable respuesta como función de las covariables observadas (Koenker y Bassett 1978). En la regresión cuantílica, en lugar de minimizar la suma de cuadrados como se haría en una regresión lineal de MCO, se minimiza una función de pérdida especial que ayuda a encontrar la mediana condicional.

$$\min_{\xi \in \mathbb{R}} \sum \rho_{\tau}(y_i - \xi)$$

La expresión anterior representa una minimización de la suma de los errores ajustados por  $\rho_{\tau}$  que es una función de pérdida específica para cuantiles. Si  $\tau = 0.5$ , la función de pérdida asigna el mismo peso a los errores positivos y negativos, obteniendo como resultado la mediana condicional. Para estimar otro cuantil, se emplea la función  $\rho_{\tau}(\cdot)$ , que cambia la forma de ponderación de los errores dependiendo de  $\tau$ .

$$\min_{\beta \in \mathbb{R}^p} \sum \rho_{\tau}(y_i - \xi(x_i, \beta))$$

Esta última expresión representa la búsqueda de los parámetros  $\beta$  que describen la relación entre  $y$  y  $x$ , ajustado para el cuantil  $\tau$ . El valor  $\rho_{\tau}$  hace que los errores por encima del cuantil  $\tau$  tengan mayor ponderación cuando  $\tau$  es alto, y menor ponderación cuando este es bajo. La minimización no puede resolverse por MCO como en la regresión lineal, sin embargo, si  $\xi(x_i, \beta)$  es una función lineal de los parámetros, esta se puede resolver mediante programación lineal.

Las regresiones cuantílicas permiten identificar los cambios en la distribución de la inflación subyacente a partir de las variaciones de sus determinantes, las cuales pueden tener efectos al alza, cuando aumentan la probabilidad de valores más altos de la inflación, y a la baja, cuando reducen la probabilidad a valores más pequeños.

Los efectos pueden ser asimétricos, moviendo las colas de la distribución en diferentes proporciones.

La especificación econométrica para las regresiones cuantílicas es la siguiente:

$$\widehat{Q}_\tau(\pi_{t+1}) = \widehat{a}_0 + \widehat{a}_1\pi_t + \widehat{a}_2E_t(\pi_{t+1}) + \widehat{a}_3x_t + \widehat{a}_4R_t + \widehat{a}_5\Delta e_t$$

Donde:

$\widehat{a}_0$  es la constante en el cuantil  $\tau$ ,  $\pi_t$  es la inflación subyacente actual,  $E_t(\pi_{t+1})$  son las expectativas de la inflación subyacente para el próximo periodo,  $x_t$  es la brecha del producto,  $R_t$  la tasa de interés y  $\Delta e_t$  la diferencia anual del tipo de cambio.  $\widehat{a}_1, \widehat{a}_2, \widehat{a}_3, \widehat{a}_4, \widehat{a}_5$  son los coeficientes asociados a cada variable, respectivamente.

Esta especificación incorpora las variables empleadas en una curva de Phillips neokeynesiana y sigue de forma similar a la propuesta por Ramos-Francia y Sidaoui (2008). Sin embargo, presenta algunas modificaciones, dado que las variables en  $t$  determinan los valores en  $t+1$ , y no contemporáneamente. La elección de variables también fue motivada por la especificación propuesta por Banco de México (2024).

Para la estimación se emplean datos mensuales desde febrero de 2018 hasta febrero de 2025. El resumen de los datos obtenidos para cada variable, su temporalidad y fuente se presenta a continuación.

**Cuadro 1:** Datos y fuentes para la estimación.

Variable	Descripción	Temporalidad	Fuente
$\pi_t$	Tasa de inflación subyacente anual	Feb/2018 - Feb/2025	SIE, Banco de México
$E_t(\pi_{t+1})$	Mediana de la encuesta sobre las expectativas de los especialistas en economía del sector privado, sobre la inflación subyacente para el siguiente periodo	Feb/2018 - Feb/2025	SIE, Banco de México
$x_t$	Brecha del producto, obtenida a partir del indicador global de la actividad económica mensual (IGAE) y el filtro Hodrick Prescott	Feb/2018 - Feb/2025	INEGI
$R_t$	Para la tasa de interés nominal se usa la tasa de rendimiento de los certificados de la tesorería a 28 días (CETES28)	Feb/2018 - Feb/2025	SIE, Banco de México
$\Delta e_t$	Diferencia anual del tipo de cambio nominal	Feb/2018 - Feb/2025	SIE, Banco de México

Se estiman las regresiones cuantílicas para los percentiles 10, 50, y 90. Los resultados se muestran a continuación.

**Cuadro 2 – Coeficientes de la regresión cuantílica.**

Variable	q = 10%	q = 50%	q = 90%
Constante	-0.1231	0.106	0.1466*
Inflación subyacente	0.967***	0.9764***	0.9639***
Expectativas de inflación	1.0495***	0.6996***	1.0278***
Brecha del producto	1.4089**	0.3687	0.0607
Tasa de interés	-0.0360***	-0.0351***	-0.0321***
Tipo de cambio	0.0420**	0.0252**	0.0112

Los signos obtenidos en la estimación son congruentes con la teoría económica; se observa persistencia de la inflación particularmente en la mediana, con efectos significativos en los tres percentiles estimados. Las expectativas destacan como un factor clave y altamente significativo en toda la distribución, los efectos marcados en los extremos resaltan su capacidad para determinar la inflación futura y al mismo tiempo destacan la importancia del anclaje de las expectativas. La producción por encima de su nivel potencial genera presiones inflacionarias importantes, y significativas solo en el percentil 10. La tasa de interés muestra efectos contractivos en la inflación, que son similares en toda la distribución, destacando su importancia como el instrumento principal de la política monetaria.

Para modelar la distribución de la inflación subyacente a partir de los percentiles obtenidos tras las regresiones cuantílicas, se utiliza una distribución normal-sesgada. Esta distribución, introducida por Azzalini (1985) es una distribución de probabilidad continua que extiende y generaliza la distribución normal mediante un parámetro adicional ( $\lambda$ ) de forma que regula la asimetría (A. Monter, E. Gonzáles, 2024).

La distribución normal sesgada, tiene parámetros de localización, escala y forma  $\xi \in \mathbb{R}$ ,  $\omega \in \mathbb{R}^+$  y  $\lambda \in \mathbb{R}$ , y su función de densidad de probabilidad está dada por:

$$f_Y(y; \xi, \omega, \lambda) = \frac{2}{\omega} \phi\left(\frac{y - \xi}{\omega}\right) \Phi\left(\lambda \frac{y - \xi}{\omega}\right), -\infty < y < \infty.$$

donde:

$\phi(z)$  es la función de densidad de la normal estándar.

$\Phi(z)$  es la función de distribución acumulada de la normal estándar.

$\xi$  es el parámetro de localización, equivalente a la media en una distribución normal.

$\omega$  es el parámetro de escala, que determina la dispersión de los datos.

$\lambda$  es el parámetro de asimetría, el cual permite modelar sesgos hacia la izquierda ( $\lambda < 0$ ) o hacia la derecha ( $\lambda > 0$ ).

Para ajustar los parámetros  $\xi$ ,  $\omega$ , y  $\lambda$  de la distribución a los valores de los percentiles  $P_{10}$ ,  $P_{50}$ , y  $P_{90}$  estimados por las regresiones cuantílicas se emplea un método de optimización numérica, con la siguiente función de error cuadrático:

$$E(\xi, \omega, \lambda) = (P_{10} - \hat{P}_{10})^2 + (P_{50} - \hat{P}_{50})^2 + (P_{90} - \hat{P}_{90})^2$$

Esta función de error mide la diferencia cuadrática entre los percentiles reales y los estimados, donde:

$P_{10}, P_{50}, P_{90}$  son los percentiles proporcionados por las regresiones cuantílicas.

$\hat{P}_{10}, \hat{P}_{50}, \hat{P}_{90}$  son los percentiles estimados de la distribución normal sesgada con parámetros  $(\xi, \omega, \lambda)$

Se minimiza la función de error cuadrático empleando el algoritmo de minimización Nelder-Mead, el cual es un método de búsqueda directa eficiente que optimiza la función de respuesta simplemente comparando sus valores. (Chang, K.-H.,2012).

La formulación computacional es la siguiente:

$$\min_{\xi, \omega, \lambda} E(\xi, \omega, \lambda)$$

Sujeto a las restricciones:

$$-10 \leq \xi \leq 10, \quad 0 \leq \omega \leq 10, \quad 0.1 \leq \lambda \leq 5.$$

Los límites se establecen con el fin de evitar soluciones no realistas, como varianzas cercanas a cero o valores de asimetría demasiado grandes.

La optimización se realiza con los siguientes valores iniciales:

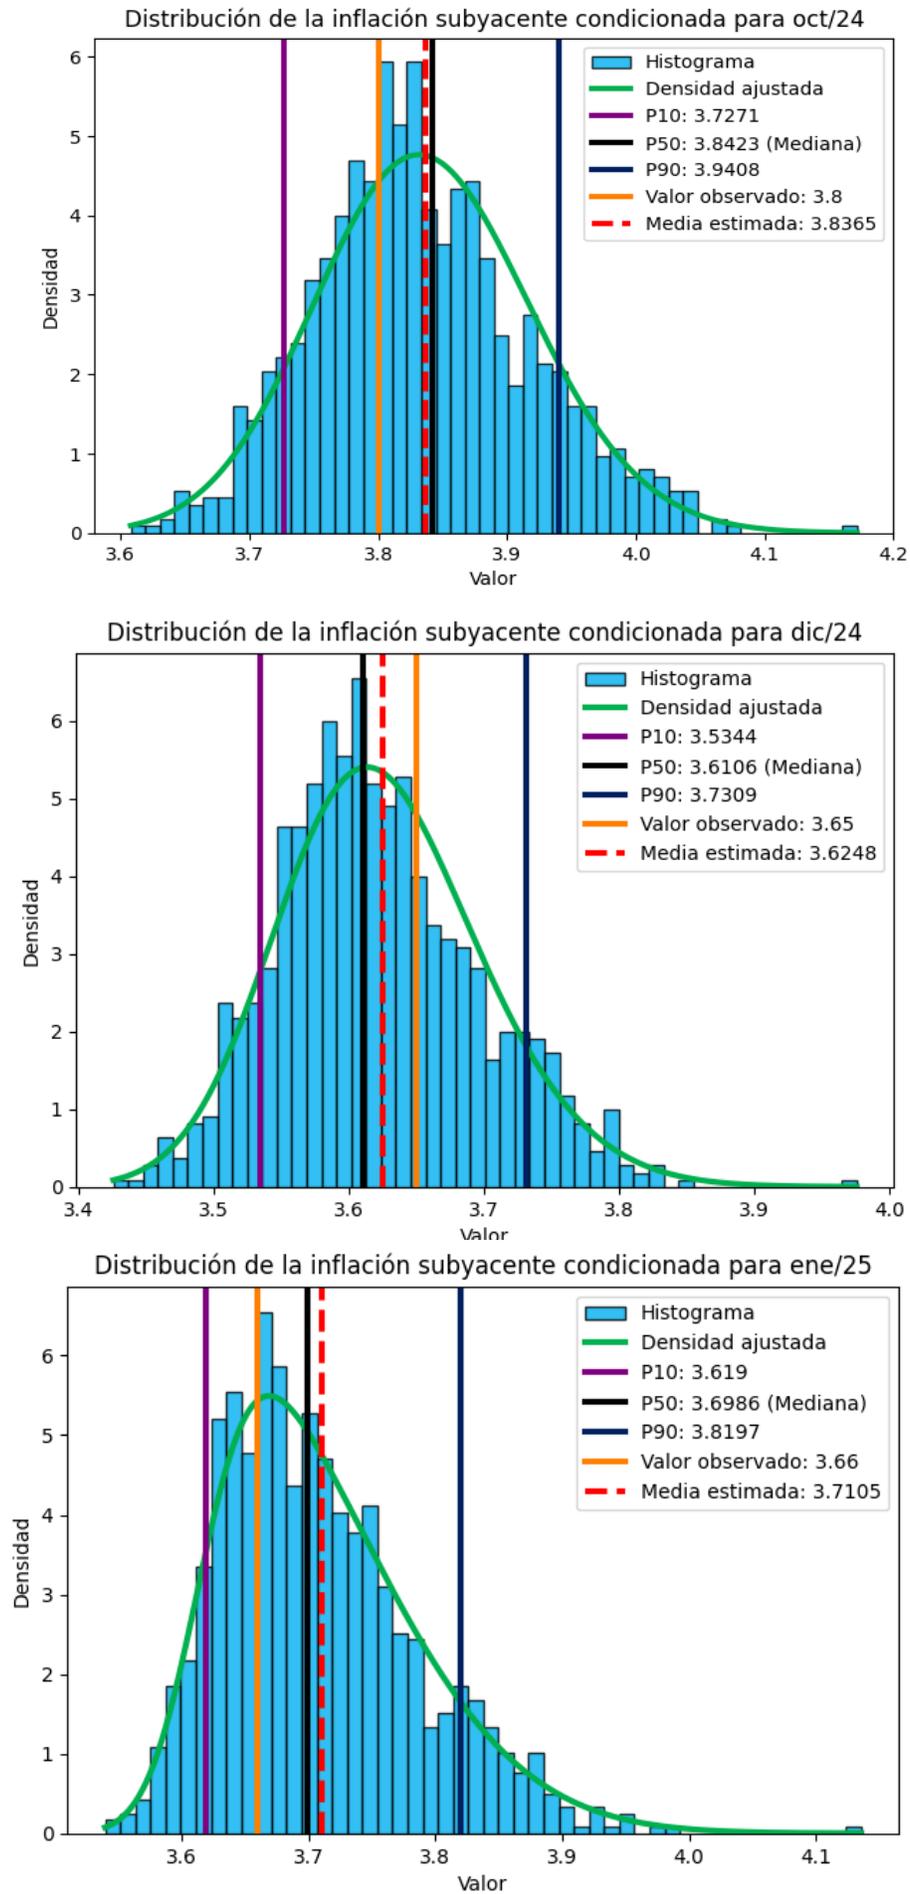
$\xi = P_{50}$ , partiendo de la hipótesis de que la mediana es un buen estimador de la localización

$\omega = \frac{P_{90} - P_{10}}{3}$ , que representa una aproximación basada en el rango interpercentil

$\lambda = 1$ , asumiendo inicialmente una asimetría.

El algoritmo es iterado hasta encontrar los valores óptimos de  $\xi, \omega, \lambda$  que minimizan la función de error. Una vez encontrado, se simulan 1000 valores aleatorios a partir de la distribución normal-sesgada ajustada. Se calcula la función de densidad y posteriormente se comparan los percentiles simulados con los estimados, asegurando que la distribución simulada ajuste a los percentiles obtenidos por las regresiones cuantílicas, reconstruyendo así la distribución de la inflación subyacente para cada observación. A continuación, se muestran las distribuciones estimadas en periodos recientes.

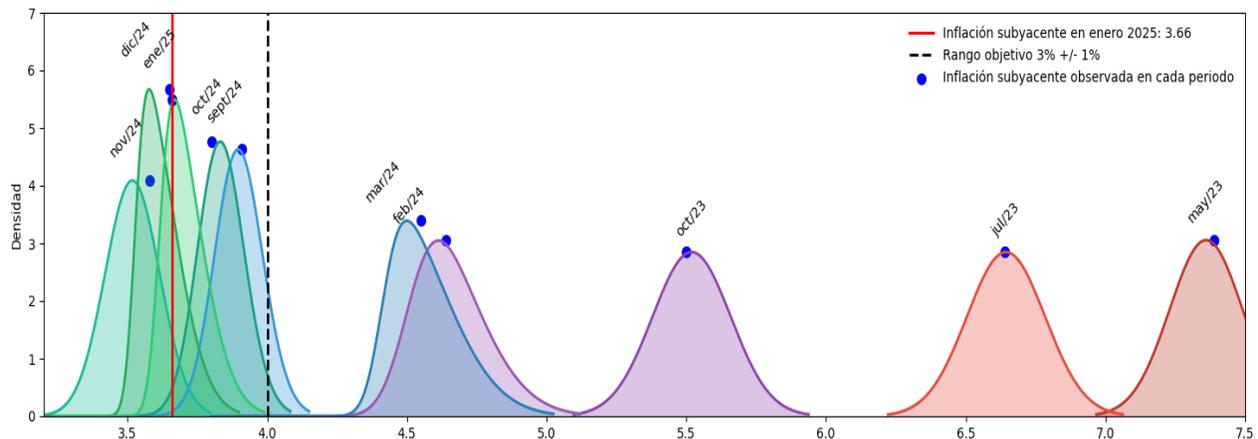
**Gráfica 3:** Estimaciones de la distribución de la inflación subyacente en periodos recientes.



## Resultados

La gráfica 4 muestra la evolución de la distribución de la inflación subyacente condicionada durante los últimos dos años. Se observa que los riesgos asociados a los determinantes de la inflación se han reducido, lo que se visualiza en distribuciones con menor dispersión, mayor apuntalamiento y progresivamente centradas en valores más bajos; además de menores asimetrías que reflejan menor persistencia en los riesgos asociados específicamente al alza. Las distribuciones muestran claramente el proceso desinflacionario desde 2023 que continúa en 2025. Desde septiembre de 2024 las distribuciones estimadas, se encuentran dentro del rango objetivo de Banco de México. Sin embargo, en diciembre de 2024 y enero de 2025, las distribuciones han mostrado un movimiento a la derecha, asociado con una aceleración de la inflación, además, la cola derecha de las mismas ha mostrado mayor dispersión, señalando que en próximos meses podría observarse una aceleración de la inflación subyacente y mayor persistencia.

**Gráfica 4:** Evolución de la distribución de la inflación subyacente 2023-2025



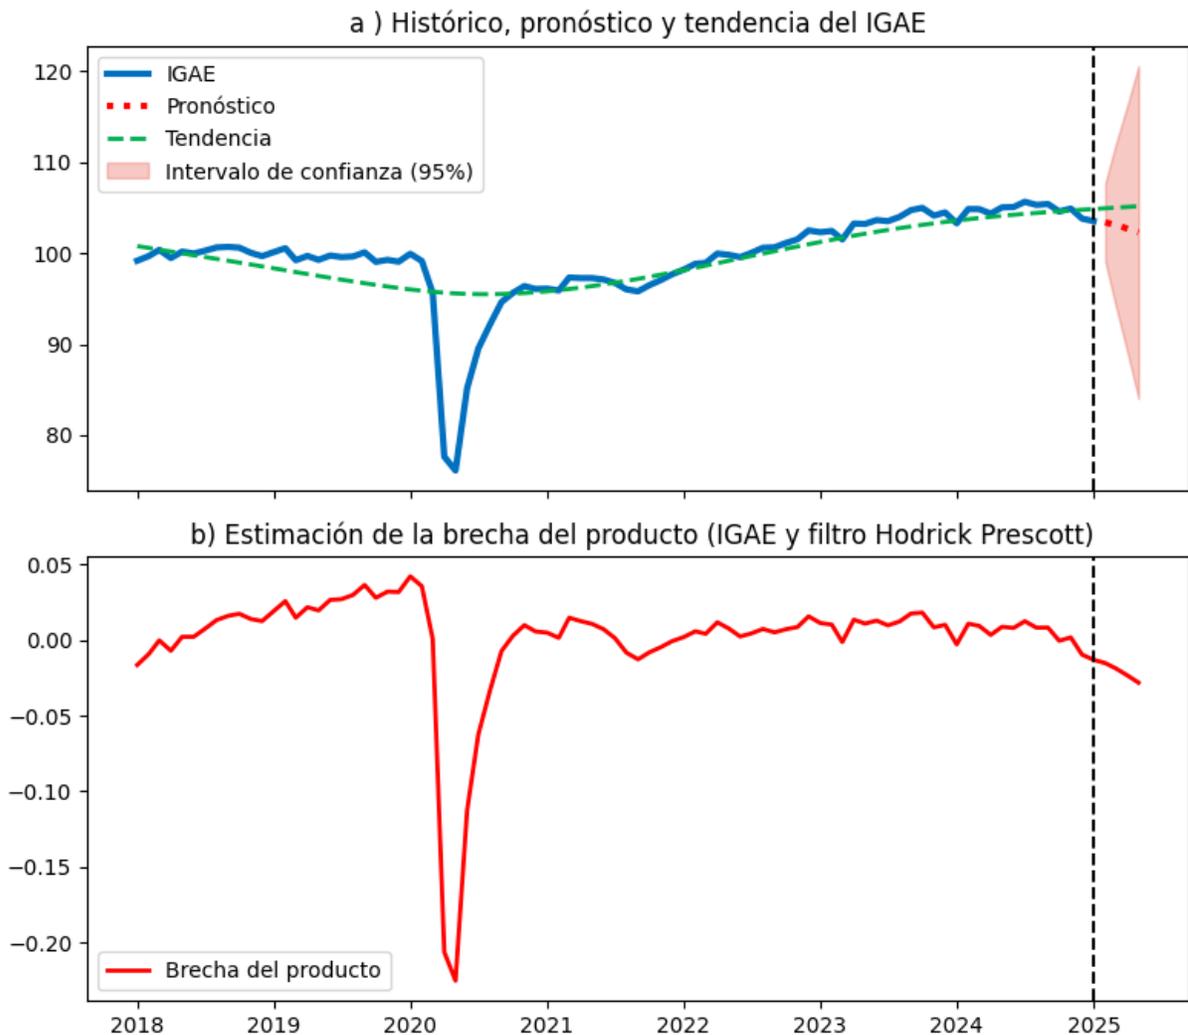
Con la finalidad de estimar la distribución de la inflación subyacente para abril de 2025, se recolectan los datos a marzo de las variables explicativas. En el caso particular de la brecha del producto: se emplea un modelo VAR(5) empleando las mismas variables mencionadas anteriormente para pronosticar el IGAE a abril de 2025. A partir del pronóstico, se obtiene la estimación de la brecha del producto al aplicar el filtro Hodrick Prescott a la serie histórica junto con los pronósticos puntuales.

El filtro de Hodrick-Prescott descompone una serie de tiempo en componentes de crecimiento y componentes cíclicos  $Y_t = Y_t^g + Y_t^c$ . Donde  $Y_t$  es el logaritmo natural de la serie y  $Y_t^g, Y_t^c$  son respectivamente, el componente de tendencia y el cíclico. (Razzak, W., 1997).

Cuando el filtro Hodrick Prescott descompone una serie temporal, como el PIB real, se obtiene el componente de tendencia (producto potencial) y un componente cíclico (la brecha del producto). Razzak, W. (1997)

En este caso, se emplea el filtro en la serie IGAE, usada como un proxy del PIB. De esta forma se descompone la serie en dos componentes, la tendencia y el ciclo. Este último representa la estimación de la brecha de producto. A continuación, se muestra el pronóstico del IGAE para febrero, marzo, abril y mayo, así como la estimación de la brecha del producto con la serie pronosticada, y el filtro Hodrick Prescott.

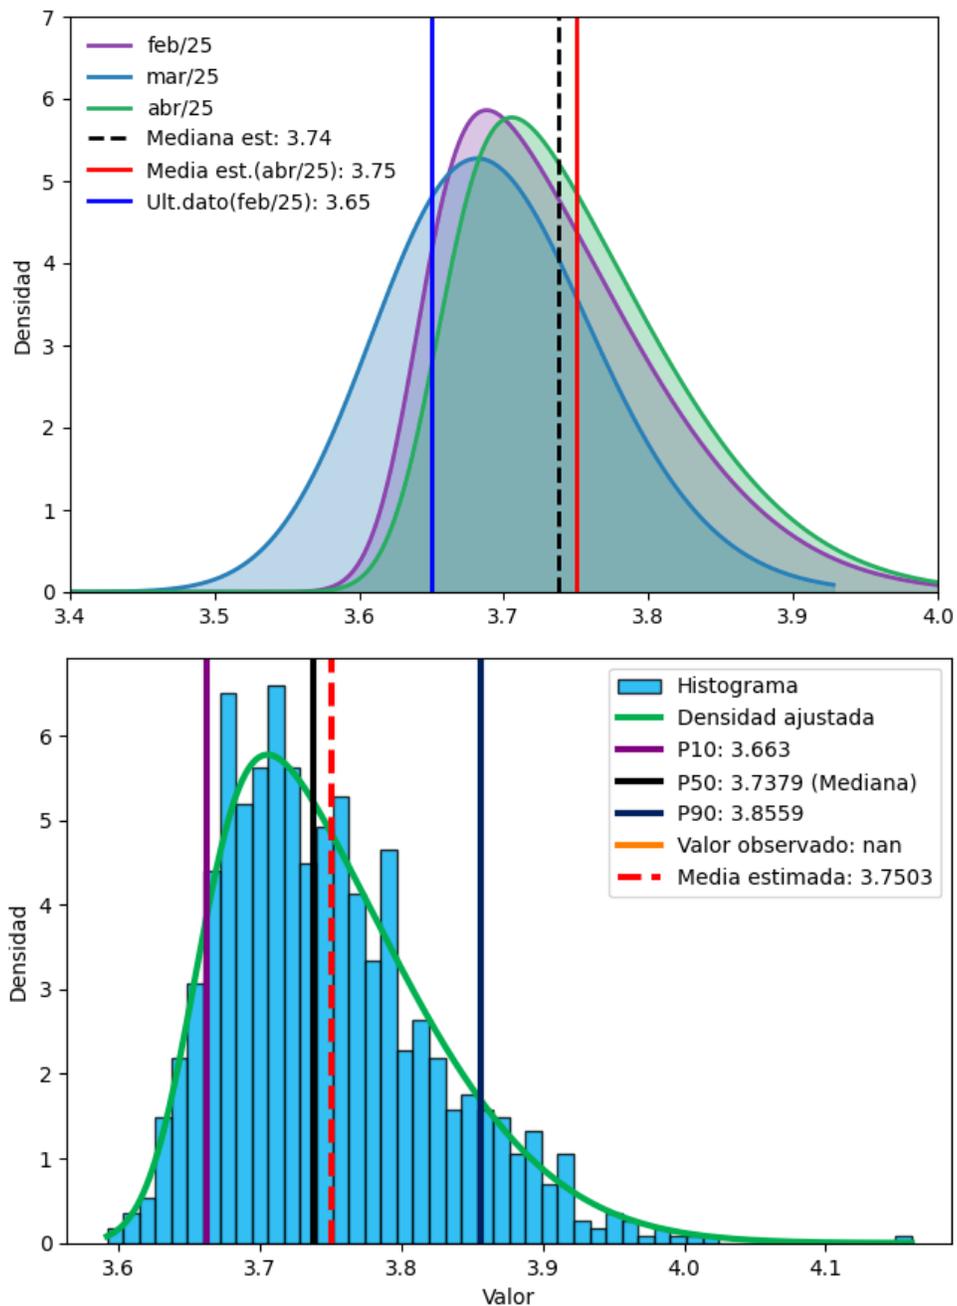
**Gráfica 5:** Pronóstico de IGAE y brecha del producto.



## Conclusiones.

Una vez obtenida la brecha del producto se estima la distribución condicional para abril con el pronóstico de la brecha para marzo, y los últimos valores del resto de variables explicativas registrados. La distribución condicionada (Gráfica 5) muestra un desplazado a la derecha, lo que implica un aumento significativo de los riesgos al alza, y la aceleración de la inflación subyacente, anticipando para abril se situará en alrededor de 3.6, y 4.0 % anual.

**Gráfica 6:** Estimación de la distribución condicional para abril.



## Referencias

- Azzalini, A. (1985). A class of distributions which includes the normal ones. *Scandinavian Journal of Statistics*, 12(2), 171–178.  
<http://www.jstor.org/stable/4615982>
- Chang, K. (2012). Stochastic Nelder–Mead simplex method – A new globally convergent direct search method for simulation optimization. *European Journal of Operational Research*, 220(3), 684–694.  
<https://www.sciencedirect.com/science/article/pii/S0377221712001609>
- Koenker, R., & Bassett, G. (1978). Regression quantiles. *Econometrica*, 46(1), 33–50.  
<https://doi.org/10.2307/1913643>
- Koenker, R., & Hallock, K. F. (2001). Quantile regression. *Journal of Economic Perspectives*, 15(4), 143–156.  
<https://pubs.aeaweb.org/doi/pdfplus/10.1257/jep.15.4.143>
- López-Salido, D., & Loria, F. (2024). Inflation at risk. *Journal of Monetary Economics*, 145(Supplement), 103570.  
<https://www.sciencedirect.com/science/article/pii/S0304393224000230>
- Monter-Pozos, A., & González-Estrada, E. (2024). On testing the skew normal distribution by using Shapiro–Wilk test. *Journal of Computational and Applied Mathematics*, 440, 115649. <https://doi.org/10.1016/j.cam.2023.115649>
- Razzak, W. (1997). The Hodrick-Prescott technique: A smoother versus a filter: An application to New Zealand GDP. *Economics Letters*, 57(2), 163–168.  
[https://doi.org/10.1016/S0165-1765\(97\)00178-X](https://doi.org/10.1016/S0165-1765(97)00178-X)