

# Midiendo el PBI potencial peruano tras la pandemia del COVID-19: un filtro multivariado extendido

**William Sánchez**

Consejo Fiscal del Perú

**Renato Vassallo**

Barcelona School of Economics

Documento de Investigación N<sup>o</sup> 03-2023

Serie de Documentos de Investigación

Agosto 2023

*Los puntos de vista expresados en este trabajo corresponden a los autores y no reflejan necesariamente la posición del Consejo Fiscal del Perú.*

*The views expressed in this paper are those of the authors and do not reflect necessarily the position of the Fiscal Council of Peru.*

Documento de Investigación N<sup>o</sup> 03-2023  
Serie de Documentos de Investigación  
Agosto 2023

*Los puntos de vista expresados en este trabajo corresponden a los autores y no reflejan necesariamente la posición del Consejo Fiscal del Perú.*

*The views expressed in this paper are those of the authors and do not reflect necessarily the position of the Fiscal Council of Peru.*

# Midiendo el PBI potencial peruano tras la pandemia del COVID-19: un filtro multivariado extendido\*

William Sánchez<sup>†</sup>

Consejo Fiscal del Perú

Renato Vassallo<sup>‡</sup>

Barcelona School of Economics

23 de agosto de 2023

## Resumen

La crisis del COVID-19 ha presentado desafíos sustanciales para macroeconomistas y hacedores de política. En particular, un choque macroeconómico de esta magnitud constituye un reto para la estimación de variables no observables como el PBI potencial, que es difícil de estimar incluso en condiciones económicas estables. En este documento proponemos un modelo macroeconómico semi-estructural para la estimación del PBI potencial peruano considerando los datos atípicos asociados a la pandemia. En particular, el modelo es utilizado como un filtro multivariado que introduce el uso de *scale factors* (Lenza y Primiceri, 2022), permitiendo una descomposición calibrada del choque pandémico en factores de oferta y demanda. Los resultados evidencian que los choques temporales de oferta fueron la principal fuente de fluctuaciones económicas durante la pandemia, explicando alrededor del 70 % de la caída del producto en 2020 y cerca del 50 % de la recuperación parcial en 2021. El hallazgo principal resalta que la crisis del COVID-19 ha exacerbado la desaceleración en el crecimiento potencial observada desde 2012, dejando secuelas estructurales en el capital humano y la productividad total de factores. Así, en ausencia de reformas estructurales que impulsen el crecimiento a mediano plazo, se estima un crecimiento potencial cercano al 2.6 % entre 2023-2027.

**Palabras clave:** *PBI potencial, crisis del COVID-19, filtro de Kalman, función de producción.*

**Clasificación JEL:** *E32, E37, C51, O47.*

---

\*Los autores agradecen los valiosos comentarios de Ozana Nadoveza (Banco Central de Croacia), Javier Escobal (GRADE), Carlos Montoro (BCRP), Alan Ledesma (BCRP), Youel Rojas (BCRP), Carlos Prieto (BCP), Juan Carlos Sosa (STCF), Gustavo Ganiko (STCF), Alvaro Jiménez (STCF) y los miembros del Consejo Fiscal del Perú. Los puntos de vista expresados en este documento corresponden a los autores y no reflejan necesariamente la posición oficial del Consejo Fiscal del Perú.

<sup>†</sup>Autor de correspondencia: William Sánchez, Dirección de Estudios Macrofiscales, Consejo Fiscal del Perú, Teléfono: (+51) 969-389-107. Correo electrónico: [william.sanchez@cf.gob.pe](mailto:william.sanchez@cf.gob.pe).

<sup>‡</sup>Renato Vassallo, Barcelona School of Economics, Correo electrónico: [renato.vassallo@bse.eu](mailto:renato.vassallo@bse.eu).

# Measuring potential output after COVID-19: an extended multivariate filter for Peru\*

William Sánchez<sup>†</sup>

Fiscal Council of Peru

Renato Vassallo<sup>‡</sup>

Barcelona School of Economics

August 23, 2023

## Abstract

The COVID-19 crisis has posed significant challenges for macroeconomists and policymakers. Estimating unobservable variables such as potential output, which is already challenging under stable economic conditions, becomes even more daunting in the face of a macroeconomic shock of this magnitude. In this paper we propose a semi-structural macroeconomic model for the estimation of Peruvian potential output considering the pandemic outliers. In particular, the model is used as a multivariate filter that introduces the use of *scale factors* (Lenza and Primiceri, 2022), allowing a calibrated decomposition of the pandemic shock into supply and demand factors. The findings reveal that temporary supply shocks played a prominent role in driving economic fluctuations during the pandemic, accounting for approximately 70% of the output decline in 2020 and nearly 50% of the partial recovery observed in 2021. The main finding highlights that the COVID-19 crisis has exacerbated the slowdown in potential growth observed since 2012, leaving structural after-effects on human capital and total factor productivity. Thus, in the absence of structural reforms to boost growth in the medium term, potential growth is estimated to be close to 2.6% between 2023-2027.

**Keywords:** *Potential output, COVID-19 crisis, Kalman Filter, Production Function.*

**JEL classification:** *E32, E37, C51, O47.*

---

\*We appreciate the comments by Ozana Nadoveza (Croatian National Bank), Javier Escobal (GRADE), Carlos Montoro (BCRP), Alan Ledesma (BCRP), Youel Rojas (BCRP), Carlos Prieto (BCP), Juan Carlos Sosa (STCF), Gustavo Ganiko (STCF), Alvaro Jiménez (PUCP), and the members of the Fiscal Council of Peru. The views expressed in this document are those of the authors and do not necessarily reflect the official position of the Fiscal Council of Peru. Any remaining error is our responsibility.

<sup>†</sup>Correspondence Author: William Sánchez, Macroeconomic Studies Department, Fiscal Council of Peru. Mobile: (+51) 969-389-107. E-mail address: [william.sanchez@cf.gob.pe](mailto:william.sanchez@cf.gob.pe).

<sup>‡</sup>Renato Vassallo, Barcelona School of Economics. E-mail address: [renato.vassallo@bse.eu](mailto:renato.vassallo@bse.eu).

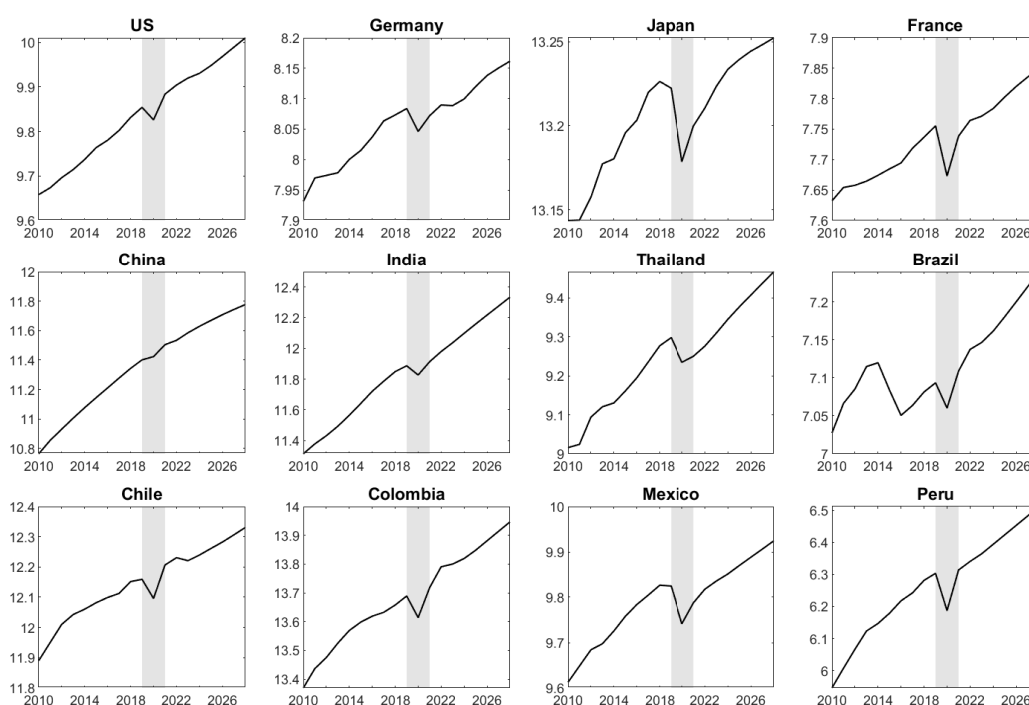
# Índice

<b>1. Introducción</b>	<b>1</b>
<b>2. Antecedentes teóricos y empíricos</b>	<b>3</b>
2.1. Literatura prepandemia . . . . .	3
2.2. Literatura pospandemia . . . . .	4
<b>3. El filtro multivariado extendido</b>	<b>6</b>
3.1. Variables observables . . . . .	6
3.2. Estructura del modelo . . . . .	6
3.2.1. PBI potencial y brecha producto . . . . .	7
3.2.2. Inflación . . . . .	8
3.2.3. Tasa de desempleo . . . . .	8
3.3. Filtro de Kalman y estimación bayesiana . . . . .	8
<b>4. Resultados</b>	<b>11</b>
4.1. Estimaciones del PBI potencial . . . . .	11
4.2. Comparación con metodologías convencionales . . . . .	12
4.3. Contabilidad del crecimiento . . . . .	14
<b>5. Conclusiones y recomendaciones de política</b>	<b>16</b>
<b>6. Agenda de investigación</b>	<b>17</b>
<b>7. Referencias</b>	<b>18</b>
<b>A. Apéndice</b>	<b>21</b>
A.1. Representación estado-espacio del filtro multivariado extendido . . . . .	21
A.2. Distribuciones Prior y Posterior . . . . .	22
A.3. Estimaciones del crecimiento potencial: distintos métodos . . . . .	23

# 1. Introducción

La crisis del COVID-19 representa un choque sin precedentes en la historia macroeconómica moderna, caracterizándose por su magnitud y alcance global, lo que la distingue de otras crisis y eventos disruptivos. Según estimaciones del Fondo Monetario Internacional (FMI), en 2020 se registró una caída de 2.8% en el crecimiento económico global, marcando la recesión más pronunciada desde la Gran Depresión de 1930. Las pérdidas de producción variaron en magnitud entre países y regiones, presentando diferencias significativas (ver Figura 1). Tanto las economías avanzadas como los mercados emergentes experimentaron interrupciones en diversos sectores como manufactura, servicios, turismo y cadenas de suministro globales.

Figura 1: PBI y crisis sanitaria



La Figura muestra la evolución del logaritmo del PBI real entre 2010 y 2028 para economías seleccionadas. Para el periodo 2023-2028 se utilizan las proyecciones del World Economic Outlook de abril de 2023. Fuente: FMI.

Las medidas drásticas implementadas como respuesta a la crisis no solo han impactado la producción observada de las economías, sino también han afectado el producto potencial. Este último se define como el nivel de producción que una economía puede alcanzar con plena utilización de los factores de producción. El crecimiento potencial juega un papel fundamental en el diseño de diversos instrumentos macroeconómicos y representa la capacidad máxima a la que puede expandirse una economía de manera sostenible en el largo plazo. De hecho, sería sumamente difícil tomar decisiones acertadas en cuanto a política fiscal y monetaria, como estímulos o medidas de austeridad, sin contar con un sólido entendimiento y adecuada medición del nivel y crecimiento potencial de una economía.

Dentro de la corriente Keynesiana en la literatura que se ocupa de estimar los ciclos económicos, se parte del supuesto de que éstas fluctuaciones son resultado de diversas perturbaciones reales que afectan exclusivamente la actividad económica a través de sus impactos en la demanda agregada, mientras que la oferta agregada evoluciona de forma gradual o suave (Woodford, 2009). En contraste con este punto de vista tradicional Keynesiano, Aguiar y Gopinath (2007) postulan que en las economías emergentes, el ciclo económico es la tendencia o está intrínsecamente ligado a la misma; idea compartida por Cerra y Saxena (2017), quienes enfatizan la importancia de reevaluar la distinción convencional entre choques de oferta y demanda, desafiando particularmente el supuesto de que los choques de demanda solo resultan en impactos económicos transitorios.

El impacto macroeconómico del COVID-19 ejemplifica claramente esta paradoja, al ser un choque que ha afectado tanto la oferta como la demanda. Al estimar el PBI potencial en el contexto de la pandemia, el desafío principal radica en descomponer este choque en una parte permanente, directamente asociada a las medidas de contención (choque de oferta temporal), y un componente transitorio estándar (choque de demanda).

En este documento desarrollamos un modelo macroeconómico sencillo con el objetivo de estimar el PBI potencial de la economía peruana, teniendo en cuenta los datos más recientes asociados a la pandemia. Específicamente, proponemos un Filtro Multivariado Extendido (FMV-X) que incorpora el uso de *scale factors*, concepto introducido por Lenza y Primiceri (2022), para descomponer el quiebre estructural del COVID-19 en un componente de largo plazo y otro componente cíclico.

Los resultados muestran que, al incorporar dichos valores extremos, la metodología aquí presentada ayuda a preservar la distribución de los parámetros del modelo, así como las propiedades y predicciones cíclicas asociadas. Asimismo, el modelo base propuesto nos permite una descomposición calibrada del choque del COVID-19 en factores de oferta y demanda, generando estimaciones que logran minimizar la revisión del PBI potencial histórico, principalmente en periodos cercanos a la crisis sanitaria. En contraste, se encuentra que los filtros convencionales generan, por un lado, una brecha del producto espuria antes y después de 2020; y por otro, revisiones importantes en las estimaciones históricas del crecimiento potencial, lo cual es difícil de sustentar económicamente, puesto que el crecimiento potencial histórico no debería cambiar.

El documento tiene seis secciones principales incluyendo esta introducción. La Sección 2 sintetiza los antecedentes teóricos y empíricos asociados a la estimación del PBI potencial, haciendo énfasis en aquellas metodologías recientes que incorporan información pospandemia. La Sección 3 describe las principales ecuaciones del FMV-X, así como los datos utilizados y el proceso de estimación. Los resultados empíricos se presentan en la Sección 4, donde se muestran: (i) estimaciones para distintos ejercicios de calibración; (ii) una comparación con metodologías convencionales; y, (iii) un ejercicio de contabilidad del crecimiento. Finalmente, la Sección 5 concluye y brinda algunas recomendaciones de política; en tanto la Sección 6 plantea una agenda de investigación futura.

## 2. Antecedentes teóricos y empíricos

### 2.1. Literatura prepandemia

La descomposición del producto en sus componentes tendencial y cíclico constituye un desafío teórico y empírico crucial en el análisis de las fluctuaciones macroeconómicas, los ciclos económicos y la formulación de políticas monetarias y fiscales. En esta tarea, existen dos enfoques comúnmente utilizados para estimar el PBI potencial. Por un lado se encuentran los filtros univariados o estadísticos, los cuales solo requieren información de la serie del PBI observado; y por otro lado, tenemos los filtros multivariados o estructurales, los cuales suelen incorporar ecuaciones de comportamiento económico en el proceso de estimación.

Las primeras contribuciones a la literatura de filtros univariados incluyen la descomposición de [Beveridge y Nelson \(1981\)](#), utilizando un modelo ARIMA sin restricciones, y el filtro de [Hodrick y Prescott \(1981, 1997\)](#), que minimiza las desviaciones de  $Y_t$  de su componente tendencial asumiendo cierto grado de suavidad de la tendencia. Posteriormente vendrían los aportes de [Baxter y King \(1999\)](#) y [Christiano y Fitzgerald \(2003\)](#) quienes desarrollan filtros de paso de banda cuyo objetivo es aislar las fluctuaciones de una serie de tiempo que se encuentran en una banda específica de frecuencias. Sin embargo, y a pesar de ser ampliamente utilizados, estos filtros han recibido profundas críticas debido a que presentan limitaciones significativas en términos de simplificaciones en su enfoque, sensibilidad a los datos extremos y falta de consideración de estructura económica ([Hamilton, 2018](#)).

Cabe notar que la mayoría de filtros univariados pueden ser expresados en términos del modelo de componente no observables (UC) de [Harvey \(1985\)](#), [Watson \(1986\)](#) y [Clark \(1987\)](#). No obstante, la gran ventaja es que este modelo no impone supuestos acerca del parámetro de suavizamiento, las ventanas de adelantos y rezagos o las frecuencias del ciclo económico. En lugar de ello, se centra en supuestos sobre el proceso subyacente de la brecha producto y el crecimiento potencial, y se estima utilizando el filtro de Kalman ([Harvey, 1990](#)). Aportes recientes en esta rama son [Perron y Wada \(2009\)](#) y [Grant y Chan \(2017a\)](#), quienes evalúan distintas especificaciones para la dinámica del componente tendencial, considerando modelos con quiebres estructurales y procesos estocásticos tanto en el nivel como en la tasa de crecimiento del componente de largo plazo.

En un esfuerzo por introducir estructura económica en los métodos estadísticos, se desarrolló una corriente en donde los modelos UC univariados son expandidos para incluir indicadores adicionales de demanda y oferta, y de esta manera mejorar la identificación de los ciclos económicos. Así, [Clark \(1989\)](#) modela la relación entre la brecha del PBI y la tasa de desempleo en un modelo UC bivariado, incorporando una ecuación que representa la Ley de Okun. Por su parte, [Kuttner \(1994\)](#) modela la relación entre inflación y brecha producto a través de una Curva de Phillips. En esta misma línea, [Roberts \(2001\)](#) utiliza horas trabajadas, inflación y PBI como variables observables en un modelo UC multivariado sin imponer restricciones en la correlación entre las innovaciones



del ciclo y la tendencia. Asimismo, [Basistha y Nelson \(2007\)](#) extienden la estructura del modelo UC para descomponer el PBI con una Curva de Phillips *forward looking* utilizando expectativas de inflación como variable observable.

La estructura económica utilizada en esta nueva generación de filtros multivariados puede clasificarse dentro de los modelos macroeconómicos dinámicos semiestructurales y modelos de equilibrio general, dinámicos y estocásticos (DSGE, por sus siglas en inglés). Aportes recientes son [Pichette et al. \(2015\)](#) del Banco Central de Canadá, [Blaggrave et al. \(2015\)](#) del FMI, [Holston et al. \(2017\)](#), para 4 economías avanzadas; y [Castillo y Florián \(2019\)](#), del Banco Central de Reserva del Perú.

## 2.2. Literatura pospandemia

Las abruptas fluctuaciones observadas en diversas variables macroeconómicas clave como consecuencia de la pandemia representan un desafío en la estimación de los modelos estándar de series de tiempo. En esta sección, presentamos una breve descripción de estudios recientes que abordan los cambios metodológicos clave en la literatura de ciclos económicos para tomar en cuenta el impacto de choques significativos y persistentes sobre la dinámica del PBI potencial.

[Lenza y Primiceri \(2022\)](#) ofrecen una solución inicial a este problema en el contexto de los modelos VAR, al incorporar explícitamente choques de volatilidad dinámicos, con el fin de capturar las innovaciones macroeconómicas excepcionalmente grandes durante el periodo pandémico. En particular, la metodología se caracteriza por la introducción de *scale factors* que permiten una amplificación transitoria de la varianza de los choques durante los meses en los que el COVID-19 impactó en la economía con mayor fuerza. Esta estrategia es adoptada por [Morley et al. \(2023\)](#), quienes estiman un modelo BVAR de gran escala para la Zona Euro controlando por observaciones atípicas, para posteriormente aplicar la descomposición Beveridge-Nelson y de esta forma obtener una medida de la brecha producto.

Por su parte, la literatura de filtros y modelos semiestructurales también ha experimentado cambios metodológicos recientes. Así, [Grguric et al. \(2022\)](#) modifican un filtro HP en su representación estado-espacio para incluir *dummies* tanto en las ecuaciones de medida como de transición del producto y controlar por la caída abrupta en 2020. Los autores logran descomponer el choque del COVID-19 en factores de oferta y de demanda. En esta misma línea, pero para un enfoque multivariado, [Banco Central de Chile \(2022\)](#) incorpora choques *exógenos* de oferta motivados en los desarrollos de la pandemia y *system priors* para preservar las propiedades del modelo al considerar la muestra completa. Cabe notar que la estrategia de incluir variables exógenas para controlar por eventos extremos en la estimación no es novedosa. Sin embargo, para estimaciones de variables no observables sí lo es: [Holston et al. \(2020\)](#) implementan esto en el contexto de la estimación de la tasa de interés neutral para Estados Unidos.

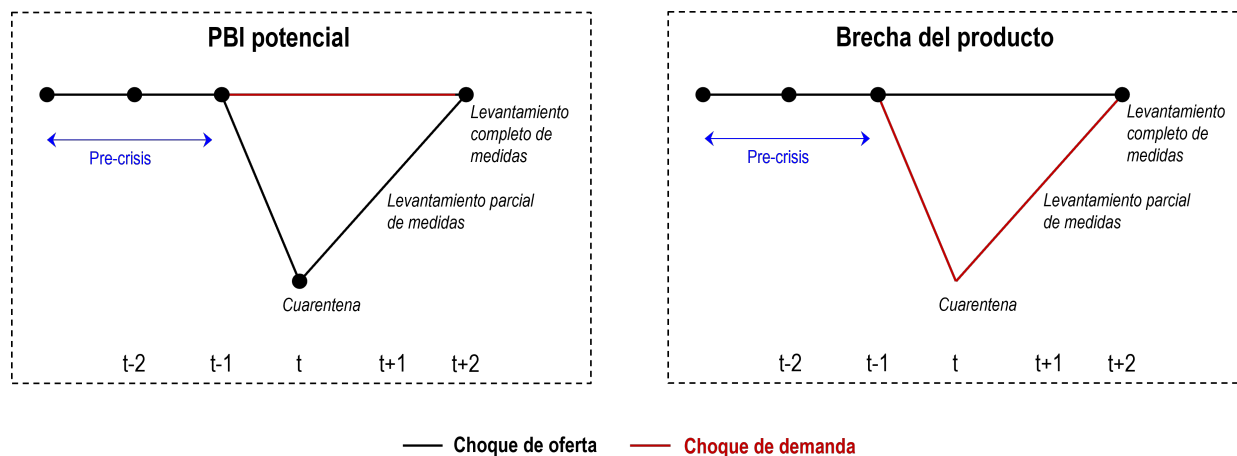
Desde otro punto de vista, y desafiando la distinción tradicional Keynesiana entre choques de oferta y demanda, [Guerrieri et al. \(2022\)](#) introduce el concepto de “choques de oferta Keynesianos”, o

caídas en el potencial que se traducen en caídas de demanda en otros sectores. Es decir, consideran que los choques de oferta tienen una dimensión de demanda. Esta idea es compartida y desarrollada por [Gómez-Pineda y Roa-Rozo \(2023\)](#) quienes proponen una descomposición ciclo-tendencia univariada con histéresis en el componente tendencial. Los autores estiman choques conjuntos de oferta y demanda, postulando que estos pueden ayudar a identificar el ciclo de la brecha producto, así como un ciclo en la tendencia.

Este documento se enmarca en la literatura de modelos semiestructurales dinámicos para el filtrado de variables macroeconómicas no observables. No obstante, proponemos una manera sencilla e intuitiva de extender su estructura tradicional para incorporar componentes determinísticos propuestos en estudios recientes para controlar por datos atípicos, y descomponer el choque del COVID-19 en una parte permanente y otra transitoria (choque de oferta y demanda).

De cara a las autoridades económicas, esta descomposición no es trivial, ya que implicaría respuestas óptimas de política posiblemente diferentes. Frente a ello, [BCE \(2020\)](#) propone, de manera ilustrativa, dos descomposiciones extremas de la caída total del PBI en 2020, las cuales se muestran en la Figura 2. La primera descomposición asume que la totalidad del choque pandémico se atribuye a las restricciones de oferta (choque de oferta transitorio y permanente), e indicaría a los hacedores de política que no es necesario actuar de forma contracíclica, ya que la brecha producto se mantiene en el nivel anterior a la crisis. En contraste, la segunda descomposición sugiere que se ha abierto una gran brecha negativa del producto y que se necesita una fuerte respuesta contracíclica.

Figura 2: Interpretación del PBI potencial y brecha del producto.



Cabe notar que estas descomposiciones extremas son solo ilustrativas y, en realidad, el PBI potencial y la brecha producto se ubicarán en algún lugar entre las dos líneas mostradas. Sin embargo, y a pesar de ser una ilustración teórica, ambos escenarios dan luz del desafío de descomponer el choque del COVID-19 en una parte de oferta y otra de demanda, y las implicancias de las diferentes descomposiciones en el proceso de formulación de políticas óptimas.

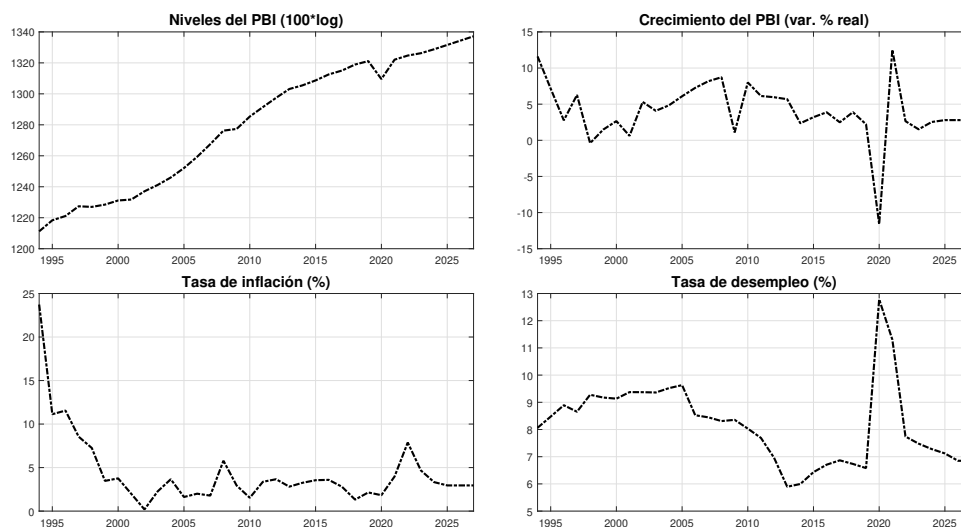
### 3. El filtro multivariado extendido

#### 3.1. Variables observables

El filtro multivariado extendido (FMV-X) especificado en este documento requiere de datos para tres variables observables: el PBI real, la inflación del IPC y la tasa de desempleo, las cuales se muestran en la Figura 3. Trabajamos con datos en frecuencia anual entre el periodo 1994 y 2022, pero se amplía la muestra hasta el año 2027 para mejorar la precisión del proceso de filtrado (estimación de las variables no observables) al final de la muestra.

Los datos son obtenidos de la página web del BCRP. En el caso de la tasa de desempleo, se completa la serie utilizando información histórica del Banco Mundial, y considerando las proyecciones del LatinFocus de julio de 2023. Para las proyecciones del PBI e inflación se tomaron los valores de la última Encuesta de Expectativas Económicas del BCRP disponible al mes de agosto de 2023<sup>1</sup>.

Figura 3: Variables observables



La Figura muestra la evolución 1994-2027 del logaritmo del PBI real peruano, escalado por 100; la tasa de crecimiento anual del PBI; la inflación anual; y la tasa de desempleo. Fuente: BCRP, Banco Mundial, FocusEconomics.

#### 3.2. Estructura del modelo

En esta Sección describimos cómo se ha estimado el PBI potencial mediante un filtro multivariado que incorpora elementos determinísticos y técnicas de calibración para controlar por *outliers* asociados al COVID-19. Empleamos un modelo semiestructural dinámico que considera las trayectorias del producto ( $Y_t$ ), la inflación ( $\pi_t$ ) y el desempleo ( $U_t$ ). Así, presentamos las ecuaciones que vinculan estas variables observables con las variables latentes en el modelo. Para estimar los parámetros y las varianzas de las perturbaciones en estas ecuaciones, aplicamos métodos bayesianos<sup>2</sup>.

<sup>1</sup>Dado que se cuenta con datos hasta 2025, se adoptan valores idénticos al último dato disponible para 2026-2027.

<sup>2</sup>Se utilizan técnicas de máxima verosimilitud regularizadas siguiendo a [Ljung \(1999\)](#) y [Hamilton \(1994\)](#).

### 3.2.1. PBI potencial y brecha producto

El PBI y sus componentes es determinado por el siguiente sistema dinámico:

$$\begin{aligned}
 (1) \quad & Y_t = \bar{Y}_t + (y_t + c_0 s_t) \\
 (2) \quad & \bar{Y}_t = \bar{Y}_{t-1} + G_t + c_1 s_t + \varepsilon_t^{\bar{Y}}, \quad \varepsilon_t^{\bar{Y}} \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \sigma_{\varepsilon_t^{\bar{Y}}}^2) \\
 (3) \quad & G_t = \theta G^{SS} + (1 - \theta)G_{t-1} + \varepsilon_t^G, \quad \varepsilon_t^G \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \sigma_{\varepsilon_t^G}^2) \\
 (4) \quad & y_t = \phi y_{t-1} + \varepsilon_t^y, \quad \varepsilon_t^y \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \sigma_{\varepsilon_t^y}^2)
 \end{aligned}$$

En la ecuación (1), definimos el PBI real en términos logarítmicos  $Y_t$  como la suma de un componente de largo plazo  $\bar{Y}_t$  (PBI potencial), y un componente cíclico o de corto plazo  $y_t$  (brecha del producto). Debido a que el choque pandémico es completamente exógeno y sabemos el momento exacto en que ocurrió, podemos tratarlo como un quiebre estructural, tanto en el nivel potencial ( $c_1 s_t$ ), como en el componente cíclico del producto ( $c_0 s_t$ ).

Al añadir el nuevo término en la ecuación (2) asumimos que el choque macroeconómico causado por el COVID-19 afectó el nivel potencial del PBI ( $\bar{Y}_t$ ) en 2020 y 2021 (choque de oferta). Por su parte, en la ecuación (1) tomamos en cuenta los efectos de las medidas de contención en el nivel del PBI que son transitorias; es decir, el resultado de restricciones temporales de suministro relacionadas con medidas epidemiológicas.

Esta metodología se caracteriza por la introducción de *scale factors* (véase [Lenza y Primiceri, 2022](#)), que permiten una amplificación transitoria de la caída del producto durante los periodos en los que el COVID-19 impactó en la economía con mayor fuerza. De manera más precisa,  $s_t = 0$  antes del periodo en que la pandemia empezó (previo al 2020). Luego, asumimos que  $s_{2020} = \bar{s}_0$ ,  $s_{2021} = \bar{s}_1$ , donde los factores  $\bar{s}_0$  y  $\bar{s}_1$  son estimados utilizando la evolución temporal de datos de movilidad registrados por Google Mobility Index, siguiendo a [Banco Central de Chile \(2022\)](#)<sup>3</sup>. Para periodos a partir de 2022 se asume que el choque pandémico se disipa; es decir,  $s_{2021+j} = 0, \forall j > 0$ .

Finalmente, el nivel de PBI potencial ( $\bar{Y}_t$ ) también evoluciona de acuerdo a una tasa de crecimiento potencial ( $G_t$ ) y a una perturbación al nivel ( $\varepsilon_t^{\bar{Y}}$ ). El crecimiento potencial en la ecuación (3) también está sujeto a choques ( $\varepsilon_t^G$ ), y su impacto se desvanece gradualmente de acuerdo con el parámetro  $\theta$  (valores más bajos implican un ajuste más lento hacia la tasa de crecimiento de estado estacionario después de un choque). Por último, la brecha del producto en la ecuación (4) también está sujeta a perturbaciones ( $\varepsilon_t^y$ ), que son en realidad choques de demanda.

<sup>3</sup>La caída en 2020 y recuperación parcial en 2021 del Google Mobility Index es utilizado como input para estimar  $s_t$ . En particular, el factor se normaliza a  $-1$  en 2020, para después observar una recuperación de 0,45 en 2021.

### 3.2.2. Inflación

Para ayudar a identificar las tres perturbaciones del producto antes mencionadas, se agrega una ecuación de curva de Phillips para la inflación, que vincula la evolución de la brecha del producto (una variable no observable) con datos observables de inflación según el siguiente proceso:

$$(5) \quad \pi_t = \lambda\pi_{t+1} + (1 - \lambda)\pi_{t-1} + \beta y_t + \varepsilon_t^\pi, \quad \varepsilon_t^\pi \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \sigma_{\varepsilon_t^\pi}^2)$$

En línea con [Kuttner \(1994\)](#), el incorporar la inflación en el modelo mejora la capacidad de identificar y estimar el componente cíclico de una economía ( $y_t$ ), al capturar las variaciones cíclicas específicas relacionadas con la inflación y separarlas de la tendencia de crecimiento a largo plazo<sup>4</sup>.

### 3.2.3. Tasa de desempleo

Finalmente, se incluyen ecuaciones que describen la evolución del desempleo para brindar mayor información identificativa para la estimación de la brecha del producto.

$$(6) \quad u_t = \bar{U}_t - U_t$$

$$(7) \quad u_t = \tau_2 u_{t-1} + \tau_1 y_t + \varepsilon_t^u, \quad \varepsilon_t^u \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \sigma_{\varepsilon_t^u}^2)$$

$$(8) \quad \bar{U}_t = \tau_4 \bar{U}^{SS} + (1 - \tau_4) \bar{U}_{t-1} + g \bar{U}_t + \varepsilon_t^{\bar{U}}, \quad \varepsilon_t^{\bar{U}} \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \sigma_{\varepsilon_t^{\bar{U}}}^2)$$

$$(9) \quad g \bar{U}_t = (1 - \tau_3) g \bar{U}_{t-1} + \varepsilon_t^{g\bar{U}}, \quad \varepsilon_t^{g\bar{U}} \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \sigma_{\varepsilon_t^{g\bar{U}}}^2)$$

En (6),  $U_t$  es la tasa de desempleo,  $\bar{U}_t$  es su nivel de equilibrio (NAIRU) y  $u_t$  es la brecha de desempleo. Especificamos una relación de la ley de Okun en la que la brecha del desempleo ( $u_t$ ) es una función de la cantidad de holgura en la economía ( $y_t$ ). Asimismo, la NAIRU está sujeta a perturbaciones ( $\varepsilon_t^{\bar{U}}$ ) y también a variaciones en la tendencia ( $g\bar{U}_t$ ), que a su vez también está sujeta a perturbaciones ( $\varepsilon_t^{g\bar{U}}$ ). Esta especificación permite desviaciones persistentes de la NAIRU de su valor de estado estacionario.

## 3.3. Filtro de Kalman y estimación bayesiana

Los estados no observables y parámetros del modelo son estimados utilizando el Filtro de Kalman, un algoritmo recursivo que puede ser aplicado de manera directa a la representación estado-espacio del modelo. Definiendo como  $\alpha_t$  al vector de estados no observables,  $y_t$  el vector de variables de medida, así como  $\varepsilon_t$  y  $\eta_t$  los vectores de choques de las ecuaciones de transición y medida, respec-

<sup>4</sup>La desviación estándar (d.e.) de los choques en la curva de Phillips determinan la parte de la varianza de la inflación explicada por los choques de costos ( $\varepsilon_t^\pi$ ). Si esta d.e. es alta, la mayoría de las fluctuaciones de la inflación se atribuirán a los choques (sin mucha implicación para la brecha producto). En cambio, si la d.e. es pequeña, las fluctuaciones de la inflación se atribuirán en parte a la brecha, afectando las estimaciones del ciclo y tendencia.

tivamente, la representación estado-espacio del modelo puede ser escrita de la siguiente manera:

$$(10) \quad \begin{aligned} y_t &= \mathbf{Z}\alpha_t + \mathbf{A}x_t + \eta_t, & \eta_t &\sim \mathcal{N}(0, \mathbf{\Sigma}_\eta) \\ \alpha_t &= \mathbf{T}\alpha_{t-1} + \mathbf{K} + \varepsilon_t, & \varepsilon_t &\sim \mathcal{N}(0, \mathbf{\Sigma}_\varepsilon) \end{aligned}$$

Dadas las medidas  $y_t$ , el vector de estado inicial  $\alpha_0$  y la covarianza de estado inicial  $P_0$  y las matrices  $\mathbf{Z}, \mathbf{A}, \mathbf{T}, \mathbf{K}, \mathbf{\Sigma}_\eta, \mathbf{\Sigma}_\varepsilon$ ; el filtro de Kalman proporciona estimaciones lineales óptimas (en términos de error cuadrático medio) de los estados no observados y su covarianza (véase el Apéndice A.1 para ver la representación estado-espacio completa del modelo).

Por su parte, los parámetros del modelo son estimados utilizando un enfoque bayesiano. La ventaja de incorporar creencias a priori a la información contenida en los datos (verosimilitud) es especialmente útil cuando el número de parámetros ( $\Theta$ ) a estimar es grande pero el tamaño de la muestra es relativamente pequeño. Aplicando el teorema de Bayes y descartando la constante de normalización que no depende de  $\Theta$ , el logaritmo de la distribución posterior,  $F(\Theta)$ , se puede expresar como la suma de la log-verosimilitud de los datos y la log-prior:

$$F(\Theta) = \sum_{t=1}^{\tau} \ln P(y_t | \Theta) + \ln P(\Theta)$$

La estimación de parámetros se realiza con la ayuda de un procedimiento bayesiano bastante estándar: primero, la moda ( $\Theta^*$ ) de la log-posterior  $F(\Theta)$  se obtiene a través de un método de optimización numérica donde la función de verosimilitud se evalúa en cada iteración del filtro de Kalman. A pesar que dicha optimización proporciona las modas posterior y la matriz hessiana correspondiente; la inferencia bayesiana adecuada requiere la distribución posterior completa. Dado el tipo de densidades utilizadas, la distribución posterior no puede derivarse analíticamente, ni están disponibles las posterior condicionales, por lo que el muestreo directo de ellas no es factible. En tales casos, la distribución posterior se puede simular utilizando un algoritmo MCMC basado en [Metropolis et al. \(1953\)](#). Así, corremos 100,000 draws de la distribución posterior con la ayuda de un algoritmo Metropolis de paseo aleatorio adaptativo, propuesto por [Haario et al. \(1999\)](#).

El Cuadro 1 resume los valores estimados y/o calibrados para los principales parámetros del modelo. Respecto a las prior, utilizamos distribuciones normales acotadas en intervalos razonables para cada parámetro, pero centradas en valores comúnmente utilizados en estudios previos. Por ejemplo, para el coeficiente  $AR(1)$  en la ecuación (4) de la brecha producto ( $\phi$ ), asumimos una moda a priori de 0.6, consistente con la creencia de que el componente cíclico del producto es estacionario, y en línea con [BCRP \(2022\)](#), quienes calibran un valor de 0.55 para este parámetro. De igual manera, para la pendiente de la Curva de Phillips en la ecuación (5) ( $\beta$ ) se asume una moda prior de 0.25 ([BCRP](#) calibra un valor de 0.12).

El Cuadro 1 también reporta la moda posterior de los parámetros obtenidos de la estimación del modelo FMV-X y, a manera de comparación, la moda posterior cuando el modelo es estimado en

la forma tradicional (sin el ajuste metodológico). Como habríamos de esperar, las estimaciones son sensibles a la especificación considerada, y en particular se encuentra que, de no controlar por datos atípicos, se podría terminar subestimando (o sobreestimando) ciertos parámetros clave del modelo. El Apéndice A.2 compara las distribuciones prior y posterior asociadas a estos parámetros.

Asimismo, los valores asignados a los parámetros calibrados son consistentes con el análisis de los principales hechos estilizados en la economía peruana, promedios históricos, consulta a expertos y juicio de los autores, con el objetivo de mejorar el poder explicativo del modelo y preservar sus propiedades al incluir nuevos datos.

Cuadro 1: Estimación y calibración de principales parámetros del modelo

Parámetro	Método	FMV-X (base)			MPT 2019
		Moda prior	Moda posterior		Valores calibrados
			Con ajuste	Sin ajuste	
<i>Producto potencial y brecha</i>					
$\phi$	Estimación	0.60	0.33	0.20	0.55
$\theta$	Estimación	0.10	0.05	0.05	-
$c_0$	Calibración	10.0	-	-	-
$c_1$	Calibración	9.00	-	-	-
$G^{ss}$	Calibración	3.00	-	-	-
<i>Curva de Phillips</i>					
$\lambda$	Estimación	0.25	0.45	0.50	0.22
$\beta$	Estimación	0.25	0.12	0.09	0.12
<i>Tasa de desempleo</i>					
$\tau_1$	Estimación	0.30	0.15	0.37	-
$\tau_2$	Estimación	0.30	0.26	0.38	-
$\tau_3$	Estimación	0.10	0.10	0.10	-
$\tau_4$	Estimación	0.10	0.10	0.10	-
$\bar{U}^{ss}$	Calibración	6.00	-	-	-

MPT 2019 muestra los valores asociados a similares parámetros en el modelo FMV-X base. Estos son calculados por BCRP (2022).

La calibración de los parámetros  $c_0$  y  $c_1$ , nos permitirá identificar y cuantificar el rol relativo de choques de oferta y de demanda en el contexto de la pandemia. En específico, calibramos el modelo siguiendo las recomendaciones de ECB (2020) y Grguric et al. (2022): (i) estimaciones históricas: preferimos una calibración que minimice las revisiones del PBI potencial histórico (hasta 2019); (ii) capacidad predictiva de brechas: la brecha producto implícita debería ser un factor importante en la explicación de la evolución de la inflación, en comparación a otros métodos; y, (iii) consistencia en el largo plazo: preferimos una calibración en la que la tasa de crecimiento del PBI potencial sea consistente con la tendencia previa a la pandemia.

## 4. Resultados

En esta Sección presentamos los principales resultados del proceso de filtrado para el PBI, así como ejercicios complementarios utilizando calibraciones alternativas y comparación de las estimaciones base versus aquellas obtenidas usando otros filtros. Asimismo, se analizan los determinantes del crecimiento potencial haciendo uso del método de Función de Producción.

### 4.1. Estimaciones del PBI potencial

La Figura 4 muestra las estimaciones del FMV-X considerando 4 calibraciones distintas para los parámetros  $c_0$  y  $c_1$ . En cada ejercicio de calibración podemos registrar cuánto de la caída en 2020 se debe al componente permanente (asociado al choque de oferta transitorio), y cuánto al componente cíclico (choque de demanda).

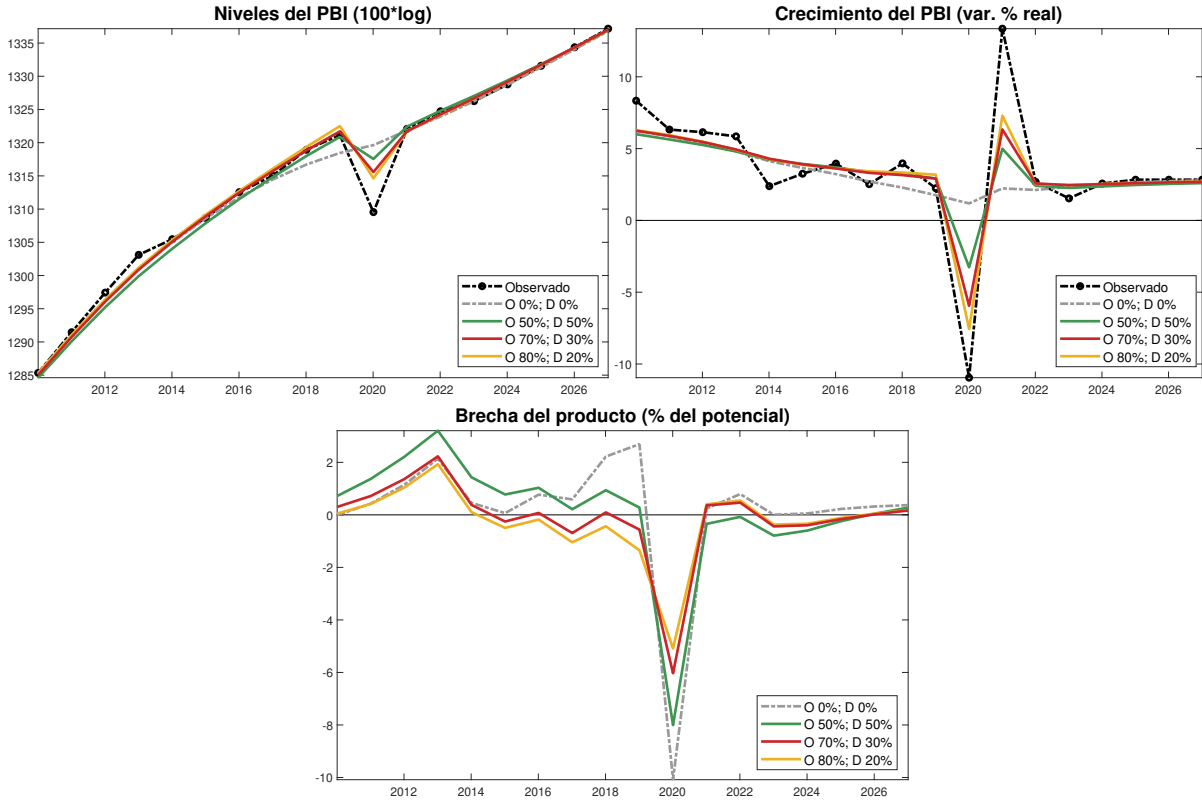
El panel superior izquierdo muestra la evolución del PBI en niveles. La línea ploma representa el FMV-X con parámetros  $c_0$  y  $c_1$  tal que el choque pandémico se descompone en 0% por el lado de la demanda, y 0% por el lado de la oferta; es decir, un filtro multivariado tradicional sin controlar por COVID-19. Se observa que a medida que el PBI potencial se acerca al 2020, se desliga del PBI observado para poder capturar la caída abrupta en la pandemia, exacerbando la caída de la brecha producto como se muestra en el panel inferior. Así, y a pesar de ser un modelo multivariado estimado con técnicas bayesianas, presenta el gran problema de producir grandes revisiones históricas. Por ejemplo, previo al COVID-19 se estimó un crecimiento potencial de alrededor de 3.0% en 2019 (véase por ejemplo [STCF \(2021\)](#) y [BCRP \(2023\)](#)). El FMV sin corregir por la pandemia haría una revisión a la baja de 3.0% a 2.4%, lo cual es difícil de sustentar económicamente, ya que en 2019 no ocurrió ningún choque abrupto que genere tal pérdida en la capacidad productiva de la economía, el choque negativo fue en 2020.

Las líneas verde, roja y amarilla representan el resultado de calibraciones alternativas de  $c_0$  y  $c_1$  donde el choque del COVID-19 comienza a ser identificado. El objetivo es encontrar aquel *set* de parámetros que minimice revisiones históricas del potencial, y que además preserve la capacidad predictiva de la brecha producto asociada a su estimación. En esta búsqueda, y siguiendo los criterios descritos en la Sección 3.3 y las recomendaciones de [BCE \(2020\)](#), los resultados del modelo base sugieren que las restricciones de oferta temporales en 2020 explicaron alrededor del 70% de la caída del producto (línea roja). Asimismo, la recuperación parcial en 2021 habría estado explicada en alrededor del 50% por estos mismos factores.

Estos resultados brindan evidencia a favor de que los choques temporales de oferta fueron la principal fuente de las fluctuaciones económicas durante la pandemia. Esto se manifiesta principalmente tanto en el lado de la producción de bienes (fábricas industriales de producción masiva), como por el lado del sector servicios (centros comerciales, hoteles, restaurantes, entre otros). En nuestro modelo, estas restricciones temporales son capturadas por el índice de movilidad de Google, que recoge



Figura 4: PBI potencial y brecha producto utilizando distintas calibraciones



Nota: La letra O denota choque de oferta y la letra D, choque de demanda. Fuente: cálculo de los autores.

información tanto del cambio abrupto generado por las cuarentenas, así como el gradual retiro de medidas. Sin embargo, es preciso señalar que los factores de oferta mencionados también habrían generado un efecto *spillover* sobre la demanda agregada, causando una reducción en los ingresos reales tras los despidos masivos, modificando los patrones de consumo e inversión, y afectando la probabilidad de encontrar empleo tras el reinicio de actividades. En este contexto, las políticas contracíclicas llevadas a cabo por las autoridades económicas constituyen un factor clave en el proceso de recuperación durante y tras la pandemia, con el propósito de limitar que se profundicen las secuelas de la pandemia en el mediano plazo.

#### 4.2. Comparación con metodologías convencionales

La Figura 5 presenta los resultados del modelo FMV-X base en comparación con metodologías comúnmente utilizadas para la estimación del PBI potencial: el filtro [Hodrick y Prescott \(1981, 1997\)](#), el filtro de paso de banda propuesto por [Baxter y King \(1999\)](#), y el modelo irrestricto de componentes no observables (UCUR) propuesto por [Grant y Chan \(2017b\)](#)<sup>5</sup>.

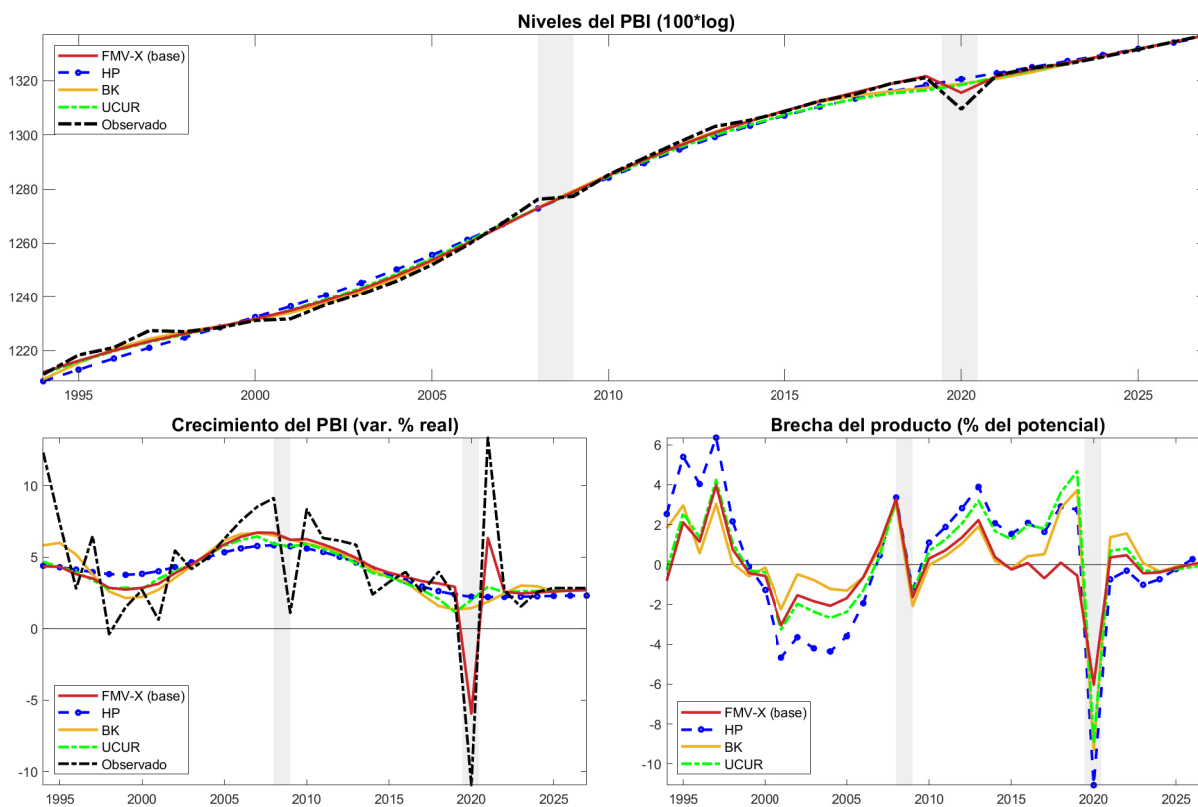
<sup>5</sup>Para el filtro HP se utilizó un parámetro de suavizamiento  $\lambda = 100$  (datos anuales). Para el filtro BK, se extraen los movimientos cíclicos que se producen entre 2 y 8 periodos, usando 3 rezagos y adelantos para extrapolar la serie.

El panel superior muestra la evolución del PBI en niveles y la medida potencial asociada a cada metodología. Como se observa en los periodos previos a la pandemia, los filtros HP, BK y UCUR comienzan a desligarse del PBI observado para capturar de manera gradual la caída en 2020. En contraste, el filtro FMV-X preserva su tendencia pre-pandemia, pero al mismo tiempo logra capturar la caída del COVID-19.

El panel inferior izquierdo presenta las tasas de crecimiento potencial. Los modelos que no incorporan esta corrección no permiten capturar efectivamente la caída del crecimiento potencial por razones intuitivas. Las estimaciones del FMV-X rompen con la dinámica gradual del crecimiento potencial reportada por los otros métodos, para incorporar la abrupta caída en 2020 y posterior rebote en 2021. Las tasas de crecimiento del PBI potencial estimadas para estas cuatro metodologías son reportadas en el Apéndice A.3.

Asimismo, y como se puede observar en el panel inferior derecho, los filtros estadísticos tradicionales generan de manera artificial una brecha del producto positiva antes de la recesión y, en el caso del filtro HP, una brecha negativa después de 2020, incluso cuando dichas brechas podrían no existir. Esta medición defectuosa de la brecha del producto podría llevar a errores por parte de los hacedores de política, lo cual ocurre precisamente en el momento en que se requiere una calibración precisa de dicha brecha.

Figura 5: Distintas medidas del PBI potencial



### 4.3. Contabilidad del crecimiento

Con el fin de obtener una mejor comprensión de los canales de transmisión por el cual el choque del COVID-19 podría estar afectando el crecimiento potencial, procedemos a descomponerlo utilizando el método de contabilidad del crecimiento. Este enfoque asume una función de producción neoclásica de retornos constantes a escala del tipo Cobb Douglas, donde los factores productivos, capital ( $K$ ), trabajo ajustado ( $\tilde{L}$ ), y la productividad total de factores ( $PTF$ ), se relacionan con el nivel de producción ( $Y$ ) de la siguiente manera:

$$Y_t = PTF_t * K_t^\alpha * (\tilde{L}_t)^{1-\alpha}$$

donde  $\alpha$  es la participación del capital físico en la producción total de la economía, el cual es calibrado en 0.5 siguiendo a [Céspedes y Rondán \(2016\)](#)<sup>6</sup>. Cabe resaltar que el factor trabajo ajustado se descompone en tres factores:

$$\tilde{L} = L * H * Q$$

donde  $L$  es la fuerza laboral, definida como la población económicamente activa (PEA),  $H$  las horas promedio trabajadas por semana, y  $Q$  un indicador del capital humano, asociado a la distribución de grados de escolaridad y años de escolaridad promedio.

El stock de capital físico se calcula siguiendo el método de inventario perpetuo:

$$K_t = (1 - \delta)K_{t-1} + I_t$$

donde  $K_t$  es el stock de capital,  $I_t$  es la inversión bruta fija obtenida del BCRP, y  $\delta$  es la tasa de depreciación, que con una depreciación lineal y una vida útil de 30 años toma el valor de 3.3%. Para mayor detalle sobre el cálculo del stock de capital, véase [MEF \(2016\)](#).

Por su parte, los datos de empleo y horas trabajadas son tomados de la base de datos de The Conference Board, publicada en abril de 2023. Asimismo, para la construcción del índice de capital humano se toman datos de escolaridad de [Barro y Lee \(2013\)](#), y del Instituto Nacional de Estadística e Informática del Perú. Finalmente, se toman las proyecciones de las mismas fuentes de datos para los años disponibles, así como tasas de crecimiento históricas para el mediano plazo.

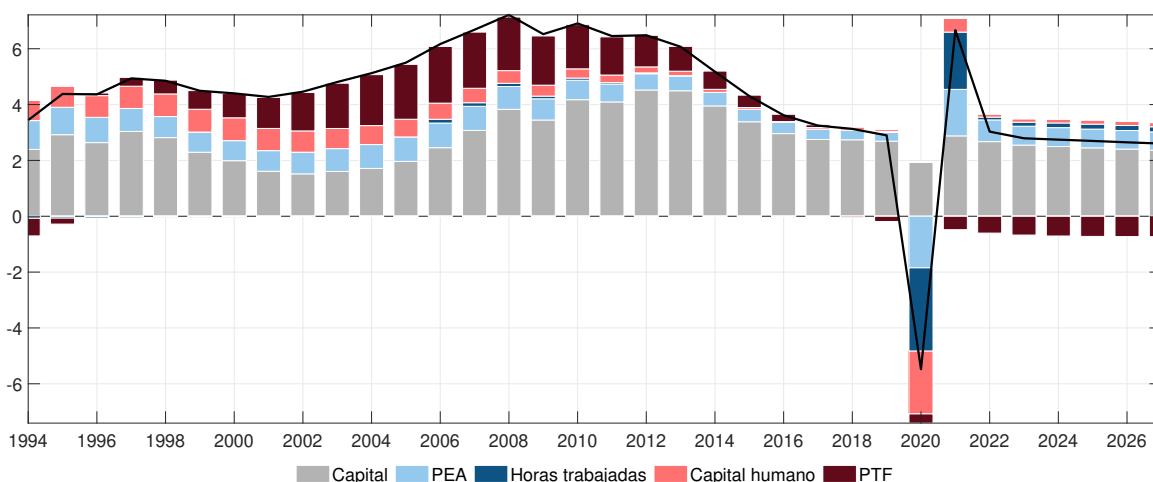
Para calcular el PBI potencial, es imprescindible estimar el nivel de tendencia de largo plazo de los factores de producción individuales. Así, el método de función de producción no es considerado un método independiente, sino que puede incorporar cualquiera de los métodos de descomposición ciclo-tendencia mencionados anteriormente. En este caso, utilizaremos una versión univariada simple de nuestra propuesta metodológica para el filtrado del factor trabajo ajustado y la  $PTF$ <sup>7</sup>. El PBI potencial se obtiene de la agregación de estas estimaciones.

<sup>6</sup>Al realizar un análisis de sensibilidad para un rango de valores de  $\alpha$  entre 0.3 y 0.7, los resultados no mostraron una variación significativa con respecto a lo reportado en nuestro modelo base.

<sup>7</sup>Se asume que el factor capital físico ( $K$ ) se encuentra en su nivel de largo plazo.

La descomposición obtenida se muestra en la Figura 6. De acuerdo a estas estimaciones, el PBI potencial en 2020 habría caído temporalmente cerca de 6.0 %, explicado casi en su totalidad por el deterioro del factor trabajo; especialmente por las horas trabajadas, cuya contribución negativa es estimada en 2.8 puntos porcentuales (p.p.), y la caída en la PEA, con una contribución negativa de 2.0 p.p.; sin embargo, ambos componentes registrarían una recuperación parcial relativamente rápida hacia 2021 en adelante. Ambos factores productivos estarían estrechamente asociados al componente transitorio del choque de oferta. Sin embargo, el choque del COVID-19 también habría generado secuelas de largo plazo, asociadas al deterioro del capital humano, una menor acumulación de capital físico y pérdida de productividad de la economía.

Figura 6: Contribución de los factores productivos al crecimiento potencial (puntos porcentuales)



En 2020 se observa que el capital humano genera una contribución negativa de 2.3 p.p. al crecimiento potencial. Sin embargo, a partir de 2021 no se observa una recuperación de la misma magnitud, denotando una pérdida estructural en el nivel de capital humano en el mediano plazo. De hecho, hacia 2027 la contribución de este factor es menor que la contribución histórica registrada entre 1994-2014. Este deterioro estaría asociado a las interrupciones prolongadas y significativas en la educación<sup>8</sup>, periodos largos fuera del mercado laboral y una actividad reducida de búsqueda de empleo y por ende, de capacitación técnica y aprendizaje profesional.

Asimismo, la menor contribución del stock de capital hacia 2027 estaría vinculada no solo a la ausencia de grandes proyectos de inversión privada, sino también a los impactos de mediano plazo derivados de los retiros anticipados de los fondos de pensiones y CTS, los cuales han generado una reducción histórica en el ahorro nacional por casi 10 p.p. del PBI entre 2020 y 2022<sup>9</sup>.

<sup>8</sup>A nivel mundial, un año adicional de educación se asocia con un aumento del 10 % en los salarios, lo que sugiere que la productividad se vería afectada por el hecho de que gran porcentaje de estudiantes vieron interrumpida su educación durante el año 2020 (Banco Mundial 2018, UNESCO 2020).

<sup>9</sup>La tasa de ahorro privado cayó de 24.9 % en 2020 a 13.5 % en 2022, alcanzando mínimos históricos en 10 años.

Finalmente, se estima una contribución persistentemente negativa de la PTF a partir de 2020. Esto contrasta con las notables ganancias de productividad generadas durante el *boom* de materias primas entre 2002-2014. En este caso, es preciso notar que la pandemia podría estar afectando la PTF de varias formas: por un lado este deterioro podría estar sustentado en que la crisis habría bloqueado temporalmente los recursos en sectores improductivos, y es probable que la reasignación hacia industrias de rápido crecimiento lleve tiempo. Además, la innovación habría sido afectada por un menor gasto en I+D tanto en el sector público, por las necesidades de consolidación, como en el sector privado, por la elevada incertidumbre. En cambio, los factores que compensan parcialmente el deterioro de la PTF estarían vinculados al mayor uso de tecnologías digitales, así como mejores términos de intercambio para economías emergentes en vista del debilitamiento global del dólar.

Es importante destacar que el método de función de producción tiene ciertas limitaciones. Durante periodos de aumento significativo en los precios de materias primas, las diversas metodologías utilizadas para medir el PBI potencial a menudo tienden a sobrestimar el cálculo de esta variable no observada. Esto se debe en gran parte a las dificultades para estimar de manera precisa la PTF, que suele estar influenciada por los términos de intercambio (Castillo y Rojas, 2014).

## 5. Conclusiones y recomendaciones de política

En este documento se desarrolla un modelo macroeconómico semiestructural con el objetivo de estimar el producto potencial de la economía peruana, teniendo en cuenta los datos más recientes relacionados a la crisis del COVID-19. El modelo base propuesto se adhiere a las recomendaciones de BCE (2020) en cuanto a las propiedades deseadas para la estimación del producto potencial, así como a las implicancias económicas de la descomposición calibrada del choque del COVID-19 en factores de oferta y demanda.

Los resultados muestran evidencia a favor de que los choques temporales de oferta fueron la principal fuente de las fluctuaciones económicas durante la pandemia, explicando alrededor del 70 % de la caída del producto en 2020 y cerca del 50 % de la recuperación parcial en 2021. Asimismo, se encuentra que los filtros estadísticos tradicionales, que no controlan por los valores atípicos de la pandemia, generan revisiones importantes en las estimaciones históricas, lo cual es difícil de sustentar económicamente, puesto que el crecimiento potencial histórico no debería cambiar.

El hallazgo principal revela que la crisis del COVID-19 ha acentuado aún más la desaceleración en el crecimiento potencial que se venía observando desde 2012. Mediante un ejercicio de contabilidad del crecimiento se evidencia que la pandemia habría dejado secuelas estructurales significativas, principalmente en el capital humano y en la productividad total de factores. De esta manera, en ausencia de reformas estructurales que ayuden a impulsar el crecimiento de mediano plazo, la economía peruana registraría un crecimiento potencial en torno a 2.6 % entre 2023-2027.

Para atenuar estas secuelas de mediano plazo y recuperar las altas tasas de crecimiento potencial

de años previos, se requiere de un rol activo de parte del Estado en la adopción y/o aceleración en la implementación de medidas destinadas a elevar la competitividad y productividad de la economía a través de: (i) la mejora sustancial del capital humano (educación y salud) para hacer frente al aumento de la desigualdad provocada a raíz la pandemia; (ii) impulsar la inversión en infraestructuras públicas, en especial en infraestructuras verdes, que contribuyan a atraer inversión privada; (iii) estrategias para fomentar y acelerar la ejecución a la inversión privada, facilitar la formalización y el desarrollo empresarial; (iv) diseñar mecanismo de diversificación de exportaciones para elevar la complejidad económica que conlleve a reducir la incidencia de volatilidad de los precios de commodities; (v) políticas que faciliten la movilidad laboral y promuevan la competencia; (vi) mayor impulso a la ciencia, tecnología e innovación; entre otros.

## 6. Agenda de investigación

El enfoque metodológico presentado en este artículo constituye un primer esfuerzo práctico para obtener estimaciones consistentes de variables macroeconómicas no observables tomando en cuenta los valores extremos registrados durante la pandemia. No obstante, avances recientes en la literatura brindan posibilidades para mejorar el modelo propuesto con el fin de afinar las estimaciones y enriquecer la discusión aquí presentada.

Un primer espacio de mejora está relacionado con la ampliación del modelo para la inclusión de datos en frecuencia trimestral, con el objetivo de lograr una identificación más minuciosa del ciclo económico.

Además, es factible aplicar *system priors*, tomando como referencia la metodología del [Banco Central de Chile \(2022\)](#), para preservar ciertas propiedades y distribuciones de parámetros durante el proceso de identificación de los componentes cíclicos y de tendencia.

Finalmente, en lugar de emplear el índice de movilidad de Google, se puede endogeneizar la variable que captura los impactos de los choques de oferta. Este enfoque, similar al utilizado por [Lenza y Primiceri \(2020\)](#), implica utilizar un SVAR bayesiano controlando estocásticamente por los valores atípicos asociados a la pandemia.

## 7. Referencias

- [1] Aguiar, M. y Gopinath, G. (2007). Emerging market business cycles: the cycle is the trend. *Journal of Political Economy* **115**(1), 69–102.
- [2] Banco Central de Chile (2022). Actualización de la metodología de estimación del PIB potencial. Informe de Política Monetaria de diciembre de 2022.
- [3] Banco Central de Reserva del Perú (2022). Modelo de Proyección Trimestral: una actualización hasta 2019. Departamento de Modelos Macroeconómicos.
- [4] Banco Central de Reserva del Perú (2023). Reporte de Inflación de marzo de 2023.
- [5] Barro, R. y Lee, J. W. (2013). A New Data Set of Educational Attainment in the World, 1950-2010. *Journal of Development Economics* **104**, 184-198.
- [6] Basistha, A. y Nelson, C. (2007). New measures of the output gap based on the forward-looking new keynesian phillips curve. *Journal of Monetary Economics* **54**(2), 498-511.
- [7] Baxter, M. y King, R. G. (1999). Measuring Business Cycles: Approximate Band-Pass Filters for Economic Time Series. *The Review of Economics and Statistics* **81**(4), 575–593.
- [8] Beveridge, S. y Nelson C. R. (1981). A new approach to decomposition of economic time series into permanent and transitory components with particular attention to measurement of the ‘business cycle’. *Journal of Monetary Economics* **7**(2), 151 – 174.
- [9] Blagrove, P., Zhang, F., Garcia Saltos, R. y Laxton, D. (2015). A Simple Multivariate Filter for Estimating Potential Output. *International Monetary Fund. Working Paper Series* 079.
- [10] Castillo, L. y Florián, D. (2019). Measuring the output gap, potential output growth and natural interest rate from a semi-structural dynamic model for Peru. *Banco Central de Reserva del Perú. Working Paper Series* **12**.
- [11] Castillo, P. y Rojas, Y. (2014). Términos de intercambio y productividad total de los factores: Evidencia empírica para economías emergentes de Latinoamérica. *Banco Central de Reserva del Perú. Working Paper Series* **12**.
- [12] Céspedes, N. y Rondán, N. R. (2016). Estimación de la productividad total de los factores en el Perú: enfoques primal y dual. En Céspedes, N., Lavado, P., and Rondán, N. R., editors, Productividad en el Perú: medición, determinantes e implicancias, **1**(2), 43-68. Fondo Editorial, Universidad del Pacífico.
- [13] Cerra, M. V. y Saxena, M. S. (2017). Booms, crises, and recoveries: a new paradigm of the business cycle and its policy implications. *International Monetary Fund. Working Paper Series* 250.
- [14] Christiano, L. J. y Fitzgerald, T. J. (2003). “The Band Pass Filter.” *International Economic Review* **44**(2), 435-65.
- [15] Clark, P. K. (1987). The cyclical component of US economic activity. *The Quarterly Journal of Economics* **102**(4), 797–814.

- [16] Clark, P. K. (1989). Trend reversion in real output and unemployment. *Journal of Econometrics* **40(1)**, 15-32.
- [17] European Central Bank (2020). The impact of COVID-19 on potential output in the euro area. *ECB Economic Bulletin* **7**.
- [18] Gómez-Pineda, J. G. y Roa-Rozo, J. (2023). A trend-cycle decomposition with hysteresis. *Borradores de Economía* 1230. Banco de la República de Colombia.
- [19] Grant, A. L. y Chan, J. C. C. (2017). A Bayesian model comparison for trend-cycle decompositions of output. *Journal of Money, Credit and Banking* **49(2-3)**, 525-552.
- [20] Grant, A. L. y Chan, J. C. C. (2017). Reconciling output gaps: Unobserved components model and Hodrick–Prescott filter. *Journal of Economic Dynamics and Control* **75**, 114-121.
- [21] Grguric, L., Nadoveza, O. y Pavic, N. (2022). The interplay of supply and demand shocks: measuring potential output in the COVID-19 pandemic. *Croatian National Bank*.
- [22] Guerrieri, V., Lorenzini, G., Straub, L., Werning, I. (2022). Macroeconomic implications of COVID-19: can negative supply shocks cause demand shortages? *American Economic Review* **112(5)**, 1437–1474.
- [23] Haario, H., Saksman, E., y Tamminen, J. (1999). Adaptive Proposal Distribution for Random Walk Metropolis Algorithm. *Computational Statistics* **14(3)**, 375-395.
- [24] Hamilton, J. (1994). Time Series Analysis. *Princeton University Press*, New Jersey.
- [25] Hamilton, J. (2018). Why You Should Never Use the Hodrick-Prescott Filter. *The Review of Economics and Statistics* **100(5)**, 831–843.
- [26] Harvey, A. C. (1985). Trends and cycles in macroeconomic time series. *Journal of Business and Economic Statistics* **3(3)**, 216–227.
- [27] Harvey, A. C. (1990). Forecasting, Structural Time Series Models and the Kalman Filter. *Cambridge University Press*.
- [28] Hodrick, R. J. y E. C. Prescott (1981). Post-War U.S. Business Cycles: An Empirical Investigation. *Discussion Papers* **451**.
- [29] Hodrick, R. J. y E. C. Prescott (1997). Postwar U.S. Business Cycles: An Empirical Investigation. *Journal of Money, Credit and Banking* **29(1)**, 1–16.
- [30] Holston, K., Laubach, T., y Williams, J. C. (2017). Measuring the natural rate of interest: International trends and determinants. *Journal of International Economics* **108(S1)**, 59-75.
- [31] Holston, K., Laubach, T., y Williams J. C. (2020). Adapting the Laubach and Williams and Holston, Laubach, and Williams Models to the COVID-19 Pandemic. Federal Reserve Bank of New York.
- [32] Kuttner, K. (1994). Estimating potential output as a latent variable. *Journal of Business Economic Statistics* **12(3)**, 361-68.



- [33] Lenza, M. y Primiceri, G. E. (2020). How to Estimate a VAR After March 2020. *Journal of Applied Econometrics* **37**, 688–699.
- [34] Ljung, L. (1999). System Identification: Theory for the User. *Prentice-Hall*, New Jersey.
- [35] Ministerio de Economía y Finanzas (2016). Metodología para el Cálculo de las Cuentas Estructurales. *Resolución Ministerial N° 024-2016-EF/15*, publicado en el Diario Oficial El Peruano.
- [36] Metropolis, N., Rosenbluth, A., Rosenbluth, M., Teller, A., y Teller, E. (1953). Equation of State Calculations by Fast Computing Machines. *The Journal of Chemical Physics* **21**.
- [37] Morley, J., Rodríguez-Palenzuela, D., Sun, Y. y Wong, B. (2023). Estimating the Euro Area Output Gap Using Multivariate Information and Addressing the COVID-19 Pandemic. *European Economic Review* **153**, 104385.
- [38] Perron, P. y Wada, T. (2009). Let's take a break: Trends and cycles in US real GDP. *Journal of Monetary Economics* **56(6)**, 749–765.
- [39] Pichette, L., St-Amant, P., Tomlin, B., y Anoma, K. (2015). Measuring Potential Output at the Bank of Canada: The Extended Multivariate Filter and the Integrated Framework. Technical report.
- [40] Roberts, J. M. (2001). Estimates of the Productivity Trend Using Time-Varying Parameter Techniques. *The B.E. Journal of Macroeconomics* **1(1)**, 1-32.
- [41] Secretaría Técnica del Consejo Fiscal (2021). Impacto de la crisis del COVID-19 sobre el PBI potencial. Recuadro 1 del Informe N° 001-2021, *Consejo Fiscal del Perú*.
- [42] Watson, M. W. (1986). Univariate detrending methods with stochastic trends. *Journal of Monetary Economics* **18(1)**, 49–75.
- [43] Woodford, M. (2009). Convergence in macroeconomics: elements of the new synthesis. *American Economic Journal: Macroeconomics* **1(1)**, 267–79.

## A. Apéndice

### A.1. Representación estado-espacio del filtro multivariado extendido

Los estados no observados y los parámetros del modelo se estiman mediante la utilización del filtro de Kalman, un algoritmo recursivo que se puede aplicar de forma sencilla a la representación espacio-estado del modelo. Definimos a  $\alpha_t$  como el vector de estados no observables,  $y_t$  el vector de variables de medida,  $\eta_t$  el vector de choques en la ecuación de medida, con media cero y matriz de covarianzas  $\Sigma_\eta$ , y finalmente  $\varepsilon_t$  es el vector de choque a las ecuaciones de estado con matriz de covarianzas  $\Sigma_\varepsilon$ . La representación estado-espacio general se puede escribir de la siguiente manera:

$$\begin{aligned} y_t &= \mathbf{Z}\alpha_t + Ax_t + \eta_t, & \eta_t &\sim \mathcal{N}(0, \Sigma_\eta) \\ \alpha_t &= \mathbf{T}\alpha_{t-1} + K + \varepsilon_t, & \varepsilon_t &\sim \mathcal{N}(0, \Sigma_\varepsilon) \end{aligned}$$

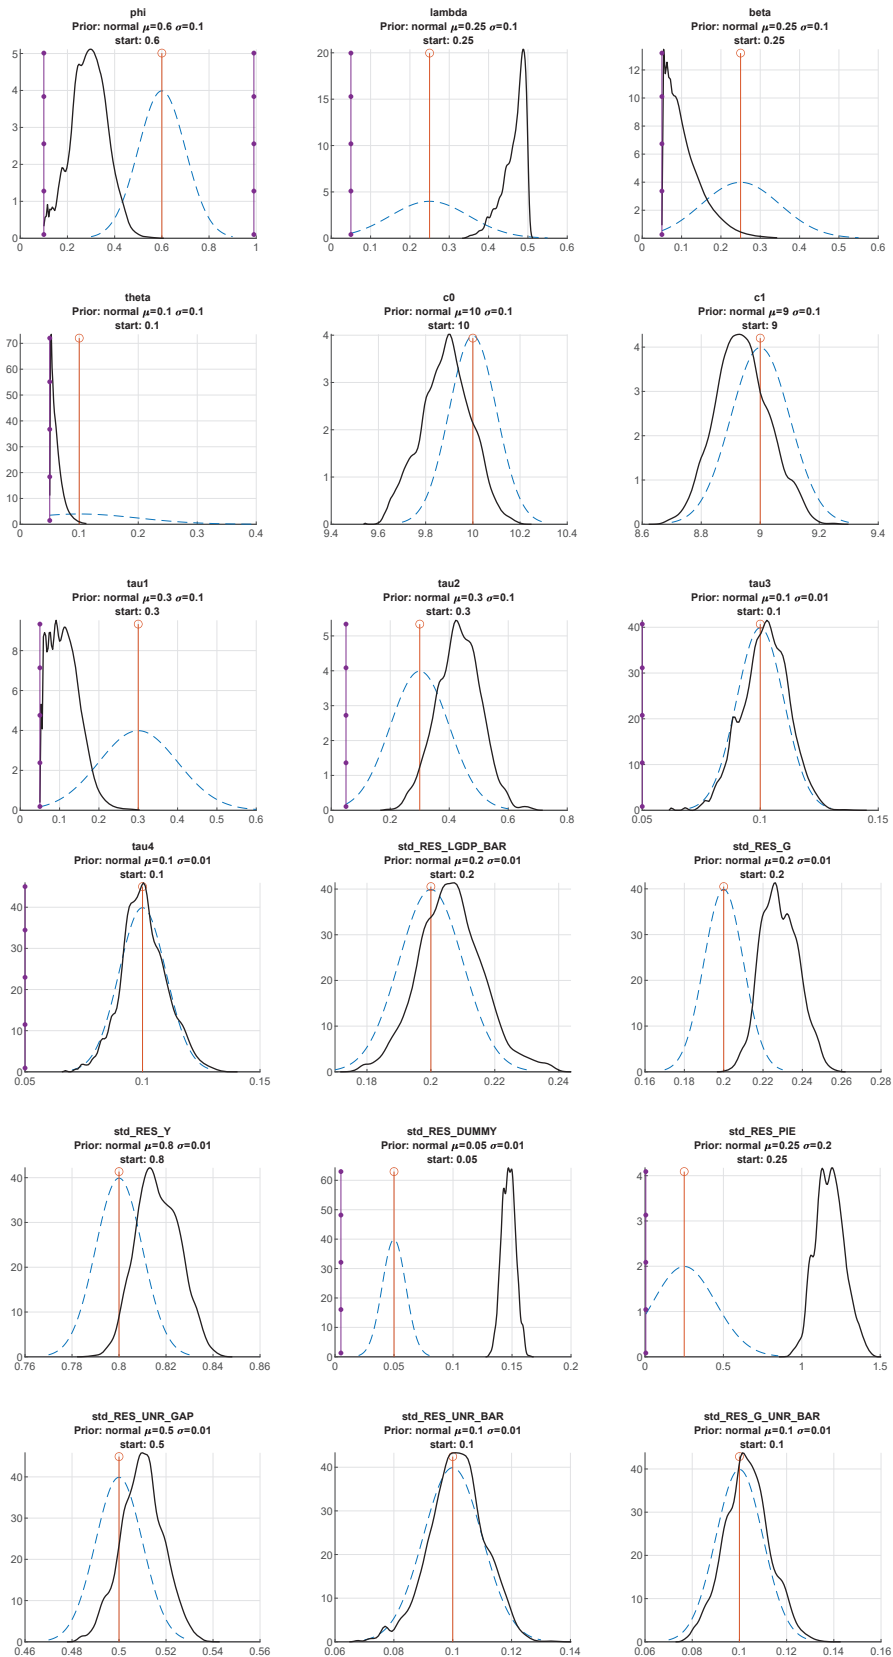
El sistema de ecuaciones (1)-(9) de la Sección 3 se puede representar mediante tres ecuaciones de medida que vinculan los valores observados del producto, inflación y desempleo  $y_t = [Y_t, \pi_t, U_t]'$ , con 8 variables de estado:  $\alpha_t = [\bar{Y}_t, y_{t+1}, y_t, G_{t+1}, G_t, \bar{U}_t, u_t, g\bar{U}_{t+1}]'$ . Así la ecuación de medida tendría la siguiente representación matricial:

$$(11) \quad \begin{pmatrix} Y_t \\ \pi_t \\ U_t \end{pmatrix} = \begin{pmatrix} 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & \beta & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & -1 & 0 \end{pmatrix} \times \begin{pmatrix} \bar{Y}_t \\ y_{t+1} \\ y_t \\ G_{t+1} \\ G_t \\ \bar{U}_t \\ u_t \\ g\bar{U}_{t+1} \end{pmatrix} + \begin{pmatrix} c_0 s_t \\ \lambda\pi_{t+1} + (1-\lambda)\pi_{t-1} \\ 0 \end{pmatrix} + \begin{pmatrix} 0 \\ \varepsilon_t^\pi \\ 0 \end{pmatrix}$$

La dinámica de las variables de estado se resume en las siguientes ecuaciones de transición:

$$(12) \quad \begin{pmatrix} \bar{Y}_t \\ y_{t+1} \\ y_t \\ G_{t+1} \\ G_t \\ \bar{U}_t \\ u_t \\ g\bar{U}_{t+1} \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & \phi & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1-\theta & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1-\tau_4 & 0 & 1 \\ 0 & \tau_1 & 0 & 0 & 0 & 0 & \tau_2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1-\tau_3 \end{pmatrix} \begin{pmatrix} \bar{Y}_{t-1} \\ y_t \\ y_{t-1} \\ G_t \\ G_{t-1} \\ \bar{U}_{t-1} \\ u_{t-1} \\ g\bar{U}_t \end{pmatrix} + \begin{pmatrix} c_1 s_t \\ 0 \\ 0 \\ \theta G^{SS} \\ 0 \\ \tau_4 \bar{U}^{SS} \\ 0 \\ 0 \end{pmatrix} + \begin{pmatrix} \varepsilon_t^{\bar{Y}} \\ \varepsilon_t^y \\ 0 \\ \varepsilon_t^G \\ 0 \\ \varepsilon_t^{\bar{U}} \\ \varepsilon_t^u \\ \varepsilon_t^{g\bar{U}} \end{pmatrix}$$

## A.2. Distribuciones Prior y Posterior



### A.3. Estimaciones del crecimiento potencial: distintos métodos

Cuadro 2: Estimaciones del crecimiento potencial peruano, 1994-2027  
(var. % real)

Año	Observado	FMV-X	HP	BK	UCUR
1994	12.3	4.4	4.4	5.8	4.7
1995	7.4	4.3	4.3	6.0	4.3
1996	2.8	3.8	4.1	5.2	4.0
1997	6.5	3.5	3.9	3.8	3.4
1998	-0.4	2.9	3.8	2.6	2.8
1999	1.5	2.7	3.8	2.1	2.9
2000	2.7	2.9	3.8	2.2	2.7
2001	0.6	3.1	4.0	2.7	3.5
2002	5.5	3.9	4.3	3.5	4.0
2003	4.2	4.5	4.6	4.4	4.5
2004	5.0	5.2	5.0	5.3	5.2
2005	6.3	5.9	5.3	6.2	5.8
2006	7.5	6.4	5.6	6.6	6.2
2007	8.5	6.7	5.8	6.7	6.4
2008	9.1	6.7	5.8	6.5	5.9
2009	1.1	6.2	5.8	6.2	5.7
2010	8.3	6.2	5.6	6.0	5.9
2011	6.3	5.9	5.4	5.7	5.6
2012	6.1	5.5	5.0	5.3	5.2
2013	5.9	4.9	4.6	4.8	4.6
2014	2.4	4.3	4.2	4.1	3.9
2015	3.3	3.9	3.7	3.6	3.6
2016	4.0	3.6	3.3	3.3	3.2
2017	2.5	3.3	2.9	2.4	2.7
2018	4.0	3.2	2.6	1.6	2.1
2019	2.2	2.9	2.4	1.3	1.2
2020	-11.0	-5.9	2.2	1.4	2.0
2021	13.3	6.3	2.2	1.9	2.9
2022	2.7	2.6	2.2	2.5	2.5
2023	1.5	2.5	2.2	3.0	2.6
2024	2.6	2.5	2.3	3.0	2.6
2025	2.8	2.6	2.3	2.6	2.7
2026	2.8	2.6	2.3	2.7	2.7
2027	2.8	2.7	2.3	2.8	2.7

Nota: para el periodo 2023-2025 se asumen las tasas de crecimiento previstas en la Encuesta de Expectativas Macroeconómicas del BCRP (agosto de 2023). Para 2026 y 2027 se adoptan valores idénticos al último dato disponible. Modelo HP: [Hodrick y Prescott \(1981, 1997\)](#), BK: [Baxter y King \(1999\)](#) y UCUR: [Grant y Chan \(2017b\)](#).

Cita recomendada:

Sánchez, W. y Vassallo, R. (2023). Midiendo el PBI potencial peruano tras la pandemia del COVID-19: un filtro multivariado extendido. *Documento de Investigación 03*, Consejo Fiscal del Perú.