

# Estimación estructural robusta a eventos de extrema variabilidad muestral

Alan Ledesma

Banco Central de Reserva del Perú

2024

# Content

1 Introducción

2 Metodología

3 Aplicación

4 Resultados

# Introducción

- Problema práctico a raíz de la pandemia de COVID-19:
  - Incremento pronunciado de la variabilidad muestral –[Ludvigson et al. 2020, BCRP 2020](#)
  - Se deterioran relaciones empíricas bien establecidas → inestabilidad y distorsión en la estimación de coeficientes y filtro de estados –[Lenza and Primiceri 2022, Carriero et al. 2022, Bobeica and Hartwig 2023](#)
  - ⇒ Se dificulta estimar descomposiciones históricas, estimación de variables latentes y de coeficientes profundos –Omitir datos no es suficiente
- Muchos esfuerzos en la literatura: [Durand and Fornero 2024](#), [Holston et al. 2023](#), [Furlanetto et al. 2023](#), [Canova 2020](#), [Grgurić and Nadoveza Jelić 2021](#), [Granados and Parra-Amado 2024](#), [Morley et al. 2023](#), ...

# Introducción

## Objetivo

- Obtener estimaciones (semi-)estructurales robustas a la pronunciada variabilidad muestral (producto de una crisis) sin alterar significativamente el algoritmo de estimación
  - Estimación de parámetros, variables latentes o descomposiciones históricas

## Supuesto

- Eventos, como la pandemia, no gatillan cambios estructurales en las relaciones económicas → secuencia continua pero transitoria de observaciones atípicas

# Introducción

## ¿Cómo?

- Tomar el escalamiento de [Lenza and Primiceri 2022](#) he introducirlo cuidadosamente en el modelo de espacio de estados
- Adaptar la recursión Bayesiana

## ¿Qué se obtiene?

- Elegir estados que absorban la volatilidad puede ser complicado
- Pero luego de esa elección, el ajuste al algoritmo tradicional es notablemente simple
- Se puede identificar la duración del evento de incremento extremo de variabilidad
- Con datos de [Holston et al. 2020](#): sin el ajuste por COVID-19 se puede subestimar la incertidumbre. En el caso de variables latentes, sus variaciones pueden estar sub/sobre estimadas.

# Consideraciones

- Análogo a Lenza and Primiceri 2022:
  - Mayor variabilidad muestral durante la pandemia → incrementos repentinos y pronunciados de la volatilidad de los choques de estado.
  - Diferencia: modelo estructural → selección de choques de estados que incrementan volatilidad
- Se “adapta” el filtro de Kalman para acomodar volatilidad extrema en períodos breves.

## Representación de estado de los espacios

$$\text{Ec. de espacio : } \mathbf{y}_t = \mathbf{Z}\boldsymbol{\alpha}_t + \mathbf{B}\mathbf{x}_t + \boldsymbol{\varepsilon}_t \quad \text{con } \boldsymbol{\varepsilon}_t \stackrel{iid}{\sim} \mathcal{N}(\mathbf{0}, \mathbf{H})$$

$$\text{Ec. de estados : } \boldsymbol{\alpha}_t = \mathbf{c} + \mathbf{T}\boldsymbol{\alpha}_{t-1} + \mathbf{R}\boldsymbol{\eta}_t \quad \text{con } \boldsymbol{\eta}_t \stackrel{iid}{\sim} \mathcal{N}(\mathbf{0}, \mathbf{Q}_t)$$

# Varianza de las variables de estado

Para  $\eta_t = [\eta_{1t} \dots \eta_{st}]'$   $\stackrel{iid}{\sim} \mathcal{N}(\mathbf{0}, \mathbf{Q}_t)$  se asume lo siguiente:

- $\eta_{it}$  (para  $i \in I$ ): Choques de estado que aumentan su volatilidad
- $\eta_{jt}$  (para  $j \notin I$ ): Choques de estado que no aumentan su volatilidad

$$\text{var}(\eta_{i,t}) = [Q_t]_{i,i} = \kappa_{i,t} q_{i,i}, \quad \forall i \in I$$

Definiendo  $\kappa_{i,t}$  como:

$$\kappa_{i,t} = \begin{cases} 1, & \text{si } t < t^* \text{ o } t > t^* + \tau^* \\ \bar{\kappa}_{i,\tau}, & \text{si } t = t^* + \tau \text{ para } \tau \in \{0, \dots, \tau^*\} \text{ e } i \in I \end{cases}$$

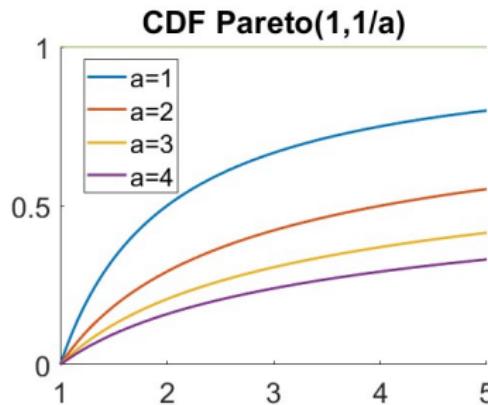
- Vector de parámetros con ajustes por pandemia  $\mathbf{s} = \{\bar{\kappa}_{i,\tau}\}_{i \in I, \tau \in \{0, \dots, \tau^*\}}$ , el resto de parámetros -habituales- se agrupan en  $\boldsymbol{\theta}$ .

# Función de densidad posterior

La función de densidad posterior es:

$$p(\theta, \mathbf{s} | \mathbf{y}^T) \propto p(\mathbf{y}^T | \theta, \mathbf{s}) p(\theta) p(\mathbf{s})$$

- $p(\mathbf{y}^T | \theta, \mathbf{s})$ : función de verosimilitud
  - Condicional a  $\mathbf{s} \Rightarrow$  se puede estimar con el filtro de Kalman, incluso si la volatilidad cambia en el tiempo.
- $p(\theta)$ , distribución *a priori* para  $\theta$ : formulación estándar.
- $p(\mathbf{s})$ , distribución *a priori* para  $\mathbf{s}$ , **consistente con valores extremos**.
  - Prior  $\bar{\kappa}_{i,\tau} \sim \text{Pareto}(1, a_i^{-1})$ , en Lenza and Primiceri 2022  $a_i = 1$



# Duración del evento

- Se puede diseñar un procedimiento para verificar el inicio y duración del evento de mayor volatilidad
- $\mathcal{M}_\tau$ : Modelo con salto de volatilidad por  $\tau + 1$  periodos.
- $\mathcal{M}_{-1}$ : modelo sin ajuste.
- Evaluación secuencial con *posterior odds ratio*:

$$\text{por}(\tau, \tau - 1) = \frac{p(\mathcal{M}_\tau | \mathbf{y}^T)}{p(\mathcal{M}_{\tau-1} | \mathbf{y}^T)} = \frac{p(\mathbf{y}^T | \mathcal{M}_\tau)}{p(\mathbf{y}^T | \mathcal{M}_{\tau-1})} \frac{p(\mathcal{M}_\tau)}{p(\mathcal{M}_{\tau-1})}$$

- $p(\mathcal{M}_j | \mathbf{y}^T)$ ,  $p(\mathcal{M}_j)$  y  $p(\mathbf{y}^T | \mathcal{M}_j)$ : probabilidad *posterior*, probabilidad *prior* y verosimilitud marginal del modelo  $\mathcal{M}_j$ , respectivamente.
  - ①  $\text{por}(0, -1) > 1$ : ajuste Covid-19 es relevante en  $t^* = 2020T1$ .
  - ②  $\text{por}(j, j - 1) > 1$  para  $j \in \{1, \dots, \tau\}$ : ajuste relevante para periodos  $t^*, \dots, t^* + j + 1$ .
  - ③  $\text{por}(\tau + 1, \tau) < 1$ : se concluye que más ajustes ya no son necesarios desde  $t^* + \tau + 1$

# Implementación



**Jeffrey Wooldridge**  
@jmwooldridge

**My motto: If I can't trick a Stata built-in command or (someone else's) user-written Stata command to do it then I'm not doing it.**

- Se puede hacer en Dynare: opción “`heteroskedastic_filter`” en función “`estimation`”
  - Ajuste COVID-19: choques auxiliares que se activan sólo en un trimestre de elevada volatilidad de correlación 1 con choque principal
  - Ejemplo:

$$\varepsilon_{it}^{\text{ajustado}} = \varepsilon_{i,t} + (\bar{\kappa}_{i,0}^{1/2} - 1)\nu_{i,0} + \cdots + (\bar{\kappa}_{i,\tau^*}^{1/2} - 1)\nu_{i,\tau^*}$$

- Prior: si  $\bar{\kappa}_{i,\tau} \sim \text{Pareto}(1, a_i^{-1}) \Rightarrow \log(\bar{\kappa}_{i,\tau}) / a_i \sim \text{Weibull}(1, 1)$

# Aplicación

- Modelo Nuevo Keynesiano basado en Holston et al. 2020.
- Diferencias: Modelos de expectativas, estimación conjunta, enfoque bayesiano y tratamiento por Covid-19.
- Objetivo: evaluar el desempeño del algoritmo propuesto.

## Ecuaciones de espacio

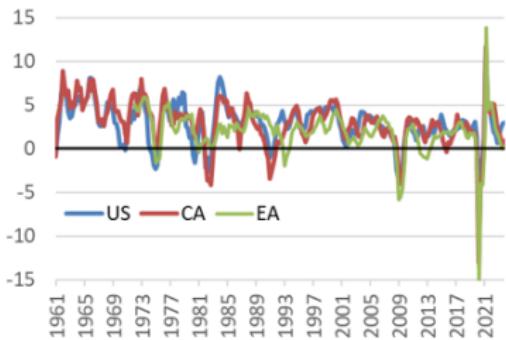
$$y_t^{obs} = \bar{y}_t + \hat{y}_t + \epsilon_t^y, \quad \epsilon_t^y \sim N(0, h_y^2)$$

$$\pi_t^{obs} = \bar{\pi} + \hat{\pi} + \epsilon_t^\pi, \quad \epsilon_t^\pi \sim N(0, h_\pi^2)$$

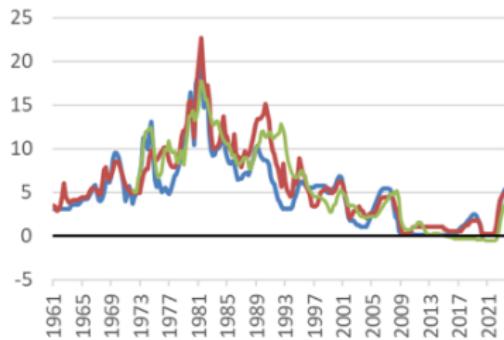
$$i_t^{obs} = i_t + \epsilon_t^i, \quad \epsilon_t^i \sim N(0, h_i^2)$$

# Aplicación

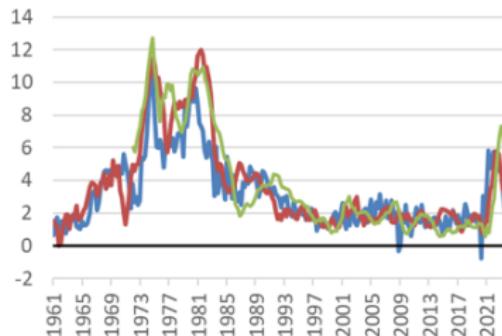
(a) Y-on-Y GDP growth rate



(b) Interest rate



(c) Inflation rate



# Aplicación: Sistema de estados

## Ciclos

$$\begin{aligned}\hat{y}_t = & a_y [a_y (a_{y1} \hat{y}_{t-1} + a_{y2} \hat{y}_{t-2}) + (1 - a_y) E_t \hat{y}_{t+1}] \\ & - a_\psi [(1 - a_{\psi1}) \psi_t + a_{\psi1} (1 - a_{\psi2}) \psi_{t-1} + a_{\psi1} a_{\psi2} \psi_{t-2}] \\ & + \varepsilon_t^{\hat{y}}, \quad \varepsilon_t^{\hat{y}} \sim N(0, \kappa_{\hat{y}, t} q_{\hat{y}}^2)\end{aligned}$$

$$\begin{aligned}\hat{\pi}_t = & b_{\pi0} \left[ b_\pi \hat{\pi}_{t-1} + (1 - b_\pi) \frac{E_t \hat{\pi}_{t+4} + E_t \hat{\pi}_{t+3} + E_t \hat{\pi}_{t+2} + E_t \hat{\pi}_{t+1}}{4} \right] \\ & + b_y [(1 - b_{y1}) \hat{y}_t + b_{y1} (1 - b_{y2}) \hat{y}_{t-1} + b_{y1} b_{y2} \hat{y}_{t-2}] \\ & + \varepsilon_t^{\hat{\pi}}, \quad \varepsilon_t^{\hat{\pi}} \sim N(0, q_{\hat{\pi}}^2)\end{aligned}$$

$$\psi_t = i_t - E_t \pi_{t+1} - \bar{r}_t$$

## Tendencias

$$\bar{y}_t = \bar{y}_{t-1} + \bar{g}_{t-1} + \varepsilon_t^{\bar{y}}, \quad \varepsilon_t^{\bar{y}} \sim N(0, \kappa_{\bar{y}, t} q_{\bar{y}}^2)$$

$$\bar{g}_t = \bar{g}_{t-1} + \varepsilon_t^{\bar{g}}, \quad \varepsilon_t^{\bar{g}} \sim N(0, q_{\bar{g}}^2)$$

$$\bar{\pi}_t = \bar{\pi}_{t-1} + \varepsilon_t^{\bar{\pi}}, \quad \varepsilon_t^{\bar{\pi}} \sim N(0, q_{\bar{\pi}}^2)$$

$$\bar{r}_t = \bar{g}_t + \bar{z}_t \text{ con } \bar{z}_t = \bar{z}_{t-1} + \varepsilon_t^{\bar{z}}, \quad \varepsilon_t^{\bar{z}} \sim N(0, q_{\bar{z}}^2)$$

# Duración del evento

**Log of posterior odd ratios**

$\mathcal{M}_0$ Vs. $\mathcal{M}_{-1}$ in 2019Q1	$\mathcal{M}_0$ Vs. $\mathcal{M}_{-1}$	$\mathcal{M}_1$ Vs. $\mathcal{M}_0$	$\mathcal{M}_2$ Vs. $\mathcal{M}_1$	$\mathcal{M}_3$ Vs. $\mathcal{M}_2$
US	-0.55	1.12	52.84	25.65
CA	-0.99	0.85	76.71	31.02
EA	-0.79	1.82	132.11	49.70

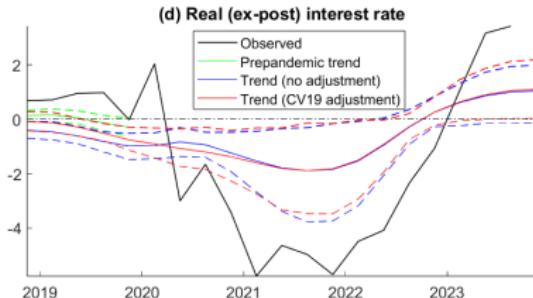
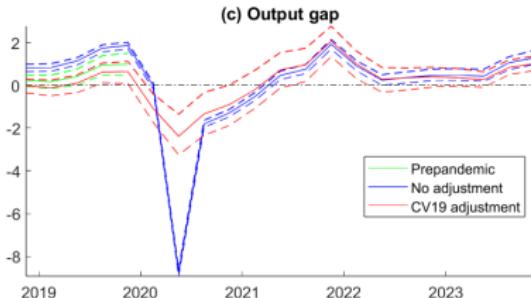
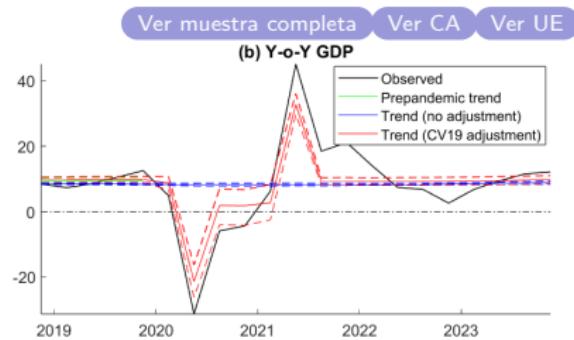
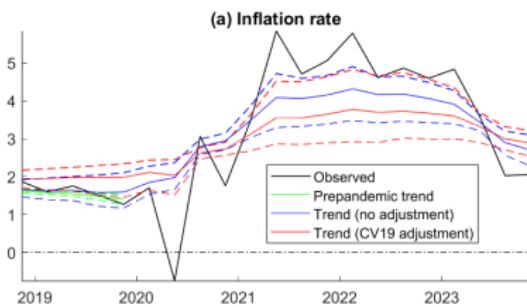
**Nota:** En la primera columna, la razón de probabilidades posterior se evaluó en una fecha aleatoria antes del brote de Covid-19. Desde la segunda columna, las evaluaciones comenzaron en el primer trimestre de 2020. Los valores en la tabla son  $\log[\text{por}(j, j - 1)]$ , un valor positivo o negativo indica preferencia por el modelo  $\mathcal{M}_j$  o  $\mathcal{M}_{j-1}$ , respectivamente.

# Estimación de coeficientes

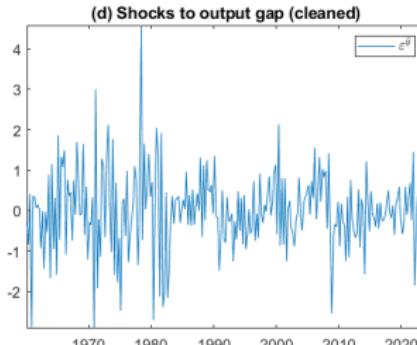
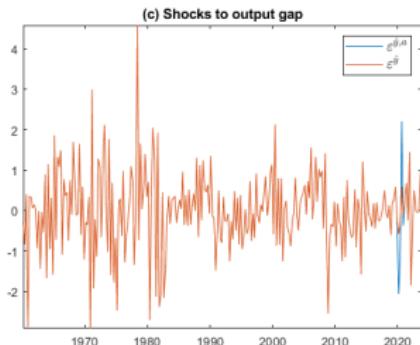
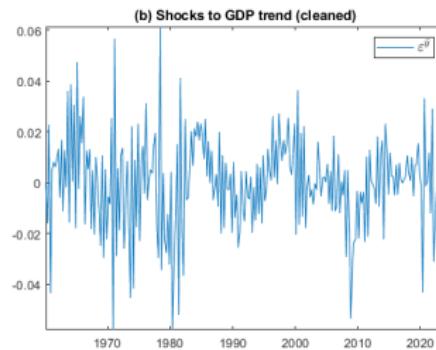
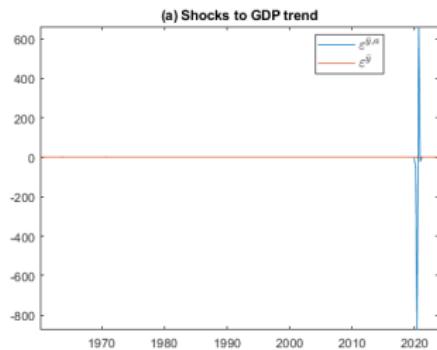
Sample and algorithm		Log data density	Dev. from pre Covid-19
US	Pre Covid-19 & linear	-1283,56	
	Complete sample & linear	-1468,56	0,72
	Complete sample & corrected	-1404,54	0,62
CA	Pre Covid-19 & linear	-1404,62	
	Complete sample & linear	-1607,97	0,41
	Complete sample & corrected	-1512,27	0,10
EA	Pre Covid-19 & linear	-927,63	
	Complete sample & linear	-1223,18	0,74
	Complete sample & corrected	-1050,11	0,55

**Note:** The term 'Deviation from pre-Covid-19' denotes the square root of the average squared change in coefficient estimations between the model utilizing the complete sample and the model employing the pre-pandemic sample.

# Estimación de variables no observables (EUA)



# Estimación de variables no observables (EUA)



# Aplicación: estimación de variables no observables

- La ausencia de la corrección subestima la incertidumbre durante y después de la pandemia.
- La estimación lineal sobreestima el efecto de la pandemia en la brecha producto.
- La brecha producto parece converger entre las estimaciones lineal y corregida a partir de 2022.
- La mayor parte del impacto de pandemia es absorbido por el nivel de PBI tendencia ( $\bar{y}$ ), en lugar que la tasa de crecimiento de largo plazo  $\bar{g}$
- La estimación lineal aísla por completo a la tendencia del efecto de la pandemia.

# Conclusiones

- Se desarrolló un algoritmo de estimación estructural robusto a eventos de cola persistentes.
- En la aplicación realizada, comprobamos que el tratamiento Covid-19 propuesto mejora el ajuste del modelo y estabiliza los coeficientes
- Por otro lado, la omisión de la corrección del Covid-19 genera problemas como incertidumbre subestimada, respuestas excesivas de la brecha producto, respuestas inadecuadas del producto tendencial y la estimación sesgada de variables no observables.

# Referencias I

-  Ludvigson, Sydney C, Sai Ma, and Serena Ng (2020). *COVID-19 and the macroeconomic effects of costly disasters*. Tech. rep. National Bureau of Economic Research.
-  BCRP (2020). *Reporte de inflación. Recuadro 4: Impactos agregados del choque COVID-19*.
-  Lenza, Michele and Giorgio E Primiceri (2022). “How to estimate a vector autoregression after March 2020”. In: *Journal of Applied Econometrics* 37.4, pp. 688–699.
-  Carriero, Andrea et al. (2022). “Addressing COVID-19 outliers in BVARs with stochastic volatility”. In: *Review of Economics and Statistics*, pp. 1–38.
-  Bobeica, Elena and Benny Hartwig (2023). “The COVID-19 shock and challenges for inflation modelling”. In: *International journal of forecasting* 39.1, pp. 519–539.

## Referencias II

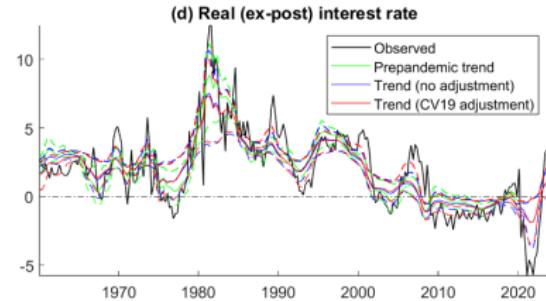
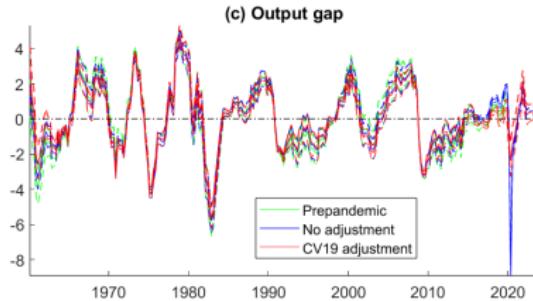
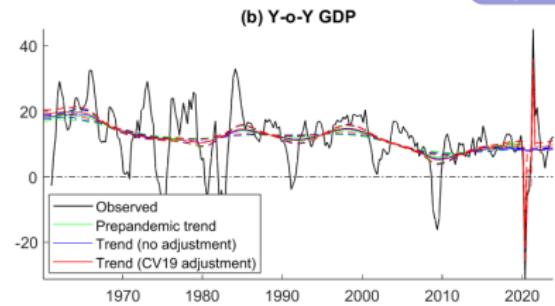
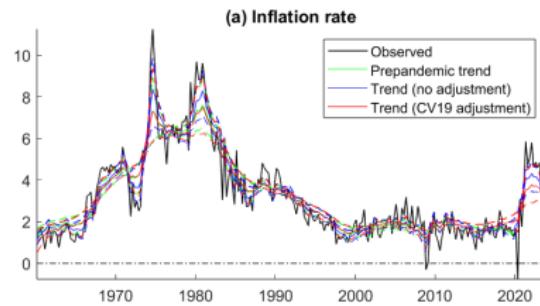
-  Durand, Luigi and Jorge A. Fornero (2024). "Estimating the output gap in times of COVID-19". In: *Latin American Journal of Central Banking* 5.4, p. 100129.
-  Holston, Kathryn, Thomas Laubach, and John C Williams (2023). "Measuring the Natural Rate of Interest after COVID-19". In: *FRB of New York Staff Report* 1063.
-  Furlanetto, Francesco et al. (2023). "Norges Bank output gap estimates: Forecasting properties, reliability, cyclical sensitivity and hysteresis". In: *Oxford Bulletin of Economics and Statistics* 85.1, pp. 238–267.
-  Canova, Fabio (2020). *FAQ: How do I extract the output gap?* Tech. rep. Sveriges Riksbank Working Paper Series.

## Referencias III

-  Grgurić, Lovorka and Ozana Nadoveza Jelić (2021). "The interplay of supply and demand shocks: measuring potential output in the COVID-19 pandemic". In: *Public sector economics* 45.4, pp. 459–493.
-  Granados, Camilo and Daniel Parra-Amado (2024). "Estimating the output gap after COVID: How to address unprecedented macroeconomic variations". In: *Economic Modelling* 135, p. 106711.
-  Morley, James et al. (2023). "Estimating the euro area output gap using multivariate information and addressing the COVID-19 pandemic". In: *European Economic Review* 153, p. 104385.
-  Holston, Kathryn, Thomas Laubach, and John C Williams (2020). "Adapting the Laubach and Williams and Holston, Laubach, and Williams models to the COVID-19 pandemic". In: *Federal Reserve Bank of New York Note*.

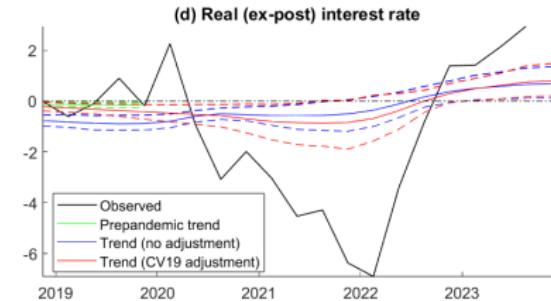
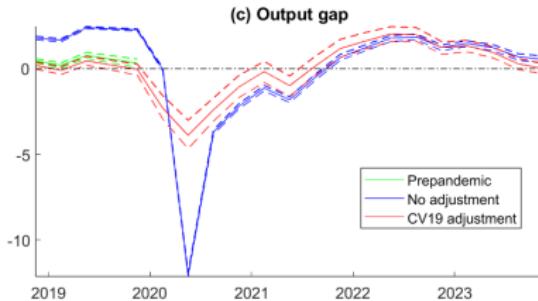
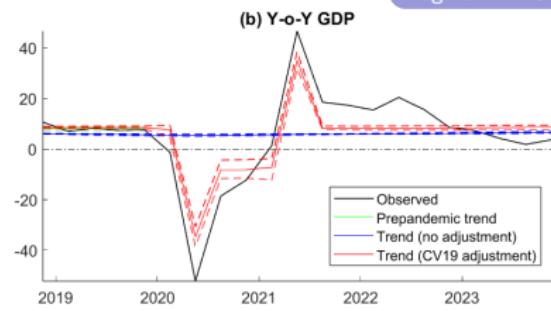
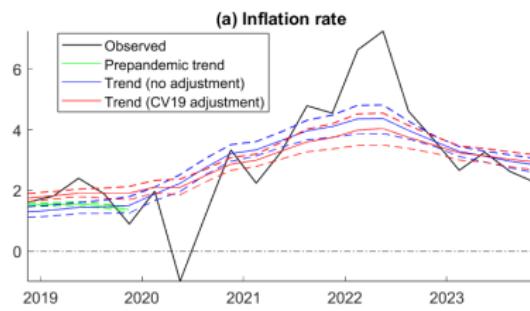
# Estimación de variables no observables (EUA) toda la muestra

[Regresar](#)



# Estimación de variables no observables (CA)

[Regresar a EUA](#)



# Estimación de variables no observables (EU)

[Regresar a EUA](#)

