

PAPELES DE TRABAJO

5/2023

Previsión de las bases tributarias mediante un modelo BVAR
de gran tamaño^(*)

ENRIQUE M. QUILIS

Servicio de Estudios Tributarios y Estadísticas

Agencia Tributaria

(*) Agradezco la colaboración y comentarios de A. Abad, A. Cuevas, R. Frutos, M. Lenza, G. Pérez-Quirós, J. Polo, S. Relloso y de participantes en seminarios en el Banco Central Europeo, Ministerio de Economía, Universidad de Santiago de Compostela y Autoridad Independiente de Responsabilidad Fiscal. Las opiniones presentadas corresponden al autor y no reflejan, de forma necesaria, la de la Agencia Tributaria



ÍNDICE

Resumen-Abstract

1. INTRODUCCIÓN
2. DATOS
3. MODELO ECONOMÉTRICO
 - 3.1. Modelo VAR
 - 3.2. Prior y calibrado
 - 3.3. Prior de Minnesota
 - 3.4. Prior de persistencia propia (*own-persistence, op*)
 - 3.5. Prior de persistencia conjunta (*co-persistence, cop*)
4. ESTIMACIÓN Y ANÁLISIS DE INTERVENCIÓN
5. ANÁLISIS ESTRUCTURAL
 - 5.1. Reducción de la dimensión
 - 5.2. Elasticidades de las bases tributarias
6. PREDICCIÓN
 - 6.1. Predicción incondicionada
 - 6.2. Predicción condicionada
 - 6.3. Esquema de predicción en tiempo real
7. CONCLUSIONES

Bibliografía

APÉNDICE A: ESTIMACIÓN MULTIVARIANTE DEL SHOCK CV19

Resumen

Se presenta una metodología para la proyección de las bases tributarias de la economía española basada en el uso de un modelo BVAR de elevada dimensión. Este modelo, completado con un análisis de intervención del *shock* COVID-19, permite realizar predicciones, evaluar escenarios externos, calcular elasticidades y generar escenarios macroeconómicos consistentes. Asimismo, ofrece una base para ejercicios de reducción de la dimensión y para la identificación de las relaciones dinámicas entre las variables.

Palabras clave: Modelos BVAR, bases tributarias, predicción, predicción condicionada, elasticidades tributarias, escenarios macroeconómicos.

Códigos JEL: C11, C32, C51, C52, C53, H24.

Abstract

We propose to forecast tax bases by means of a large BVAR of the Spanish economy. The model supports a multivariate intervention analysis to assess the role of the COVID-19 shock and allows us to generate forecasts (unconditional as well as conditional), evaluate external scenarios and ensure the internal consistency of the projections. At the same time, the model provides ways for dimension reduction and for the identification of the dynamic interactions among the variables.

Keywords: BVAR models, tax bases, forecasting, conditional forecasting, tax elasticities, macroeconomic scenarios.

JEL Codes: C11, C32, C51, C52, C53, H24.

1. INTRODUCCIÓN

La proyección de la recaudación tributaria es un ejercicio fundamental para la planificación presupuestaria, posibilitando la fijación de objetivos consistentes con sus fundamentos macroeconómicos, permitiendo la comparación de los resultados efectivos con las previsiones, identificando las fuentes de las desviaciones y cuantificando las medidas correctoras precisas. Estas proyecciones descansan en la siguiente relación (Frutos *et al.*, 2003):

$$[1] \quad T_t = \tau_t B_t m_t$$

Siendo:

- T_t : recaudación efectiva generada durante el periodo t .
- τ_t : tipo impositivo.
- B_t : base tributaria sobre la que se aplica el impuesto.
- m_t : factor de mecánica recaudatoria.
- t : intervalo temporal de referencia (p.e., trimestre).

Todas las variables contenidas en [1] están valoradas a precios corrientes y en términos de devengo¹, esto es, asociada a la posición financiera final del Estado atribuible al periodo t .

La descomposición planteada en [1] es especialmente conveniente, ya que permite delimitar los factores normativos (τ_t), económicos (B_t) y de gestión (m_t). Para fines predictivos, el primero y el último se pueden considerar exógenos. El factor normativo forma parte de la configuración tributaria del Estado, formulada legislativamente por el Parlamento y que puede ser considerada como exógena².

El factor de mecánica recaudatoria es, conceptualmente, un término estacionario centrado en 1, muy vinculado con las campañas tributarias y diversos elementos de gestión que pueden dar lugar a desfases entre la recaudación nocial ($\tau_t B_t$) y la efectiva (T_t).

Finalmente, la base tributaria define el flujo económico generado durante el periodo t y que es objeto de imposición. Su comportamiento está ligado a un amplio conjunto de factores macroeconómicos (entorno exterior, crecimiento real, empleo, inflación, condiciones financieras y monetarias, posición cíclica). De esta manera, asumiendo constancia normativa y de gestión, la proyección de las bases tributarias estará vinculada con la de sus correspondientes determinantes macroeconómicos.

¹ La valoración en términos de devengo se deriva de la correspondiente en términos de caja (o tesorería). Esta última refleja la variación de la posición financiera del Estado resultado de las cuentas abiertas con los contribuyentes en las que figuran pagos a cuenta y fraccionados, devoluciones, rectificaciones y revisiones, aplazamientos, etc.

² Esta hipótesis es válida para los impuestos progresivos de forma aproximada, debido a la dependencia del tipo respecto a la base. La forma apropiada para tener en cuenta esta dependencia requiere el uso de información detallada a nivel transversal, que está disponible con cierto retraso y en frecuencia anual (QUILIS y FRUTOS, 2020).

En este trabajo se utiliza un modelo vectorial de autorregresiones bayesianas (BVAR)³ de elevada dimensión⁴ para proyectar las bases tributarias de los principales impuestos de la economía española junto con sus determinantes macroeconómicos.

La elevada dimensión del modelo asegura que todos los factores macroeconómicos relevantes antes mencionados son tenidos en cuenta y, además, con un grado de detalle adecuado. De esta manera, se resuelve el problema de variables omitidas asociado a los modelos BVAR pequeños y medianos. Este problema puede sesgar tanto las previsiones como, especialmente, la inferencia estructural.

El modelo BVAR es estimado en frecuencia trimestral, obteniéndose un adecuado compromiso entre la cobertura temporal intraanual y la rapidez en la disponibilidad de la información de base (*timeliness*). Como se verá más adelante, más de la mitad de las variables del modelo son de frecuencia mensual, por lo que se pueden utilizar técnicas de previsión en tiempo real (*nowcasting*) para completar el panel de datos, asegurando así una actualización permanente del mismo (Cuevas *et al.*, 2017, 2019). Finalmente, la frecuencia trimestral es especial conveniente para el tipo principal de proyecciones a medio plazo que se desea realizar, con un horizonte entre 1 y 2 años.

Desde un punto de vista econométrico, la estructura bayesiana empleada, además de estabilizar las estimaciones, permite la incorporación flexible, no dogmática, de relaciones de equilibrio a largo plazo entre los niveles de las variables involucradas (cointegración).

Las predicciones incondicionadas del modelo dan lugar a un escenario inercial que, acompañado por los correspondientes intervalos de confianza, ofrece una referencia inicial estadísticamente fundamentada en ausencia de cambios normativos (*no policy change*).

Los modelos BVAR han experimentado un notable desarrollo en los últimos años, tanto desde el punto de vista de las técnicas empleadas para su estimación como en el ámbito de sus aplicaciones, consolidando su papel como herramienta básica del análisis macroeconómico aplicado. Dentro de estos desarrollos, cabe mencionar:

- Diseño de un amplio número de priores: derivados de modelos DSGE (*Dynamic Stochastic General Equilibrium*), adaptados para series estacionales, incorporando información sobre el estado estacionario, etc. En muchos casos, la implementación de estos priores se realiza mediante el método de variables ficticias, que permite un tratamiento computacionalmente conveniente.
- Métodos de estimación numéricos, mediante técnicas MCMC (*Markov Chain Monte Carlo*) como el *Gibbs Sampler* (GS), que permiten una estimación propiamente bayesiana de estos modelos.

³ BVAR, por Bayesian Vector of Autoregressions.

⁴ De forma convencional, la dimensión de un BVAR puede ser pequeña (entre 2 y 4 variables), mediana (entre 5 y 15 variables) o elevada (más de 15 variables). El modelo que se presenta en este trabajo contiene 24 variables.

- Métodos de calibrado perfeccionados, de forma que un paso crucial de estos modelos, la determinación de sus hiperparámetros, puede desarrollarse de forma eficiente y convincente.
- Avances en la interpretación estructural de los BVAR: restricciones de signo o funciones de impulso-respuesta generalizadas.
- Predicción condicionada, de forma que se pueden analizar escenarios alternativos bien directamente sobre las variables observadas bien sobre los *shocks* últimos que inciden sobre el sistema.
- Modelos de frecuencia mixta.

En conjunto, todos estos avances han hecho de los BVAR una herramienta para el análisis cuantitativo potente y flexible, compitiendo con los modelos factoriales dinámicos en tareas de predicción en tiempo real (*nowcasting*) o con los DSGE en labores de análisis estructural como, p.e., la evaluación de políticas económicas.

En particular, la previsión condicionada es una técnica muy eficaz que permite incorporar sendas específicas para ciertas variables que articulan a las proyecciones oficiales (p.e. el cuadro macroeconómico asociado a los Presupuestos Generales del Estado, PGE), medidas de política (p.e. sendas para el tipo de intervención del Banco Central Europeo, BCE) o escenarios de estrés (p.e. asociados a conflictos geopolíticos y a sus posibles efectos económicos). Adicionalmente, esta metodología puede ser utilizada para comprobar la consistencia de las proyecciones tributarias con el escenario macroeconómico, ofreciendo una vía objetiva y sencilla para examinar su realismo.

El texto está organizado de la forma siguiente. La base de datos utilizada se presenta en la segunda sección y, en la tercera, el modelo econométrico. La sección cuarta detalla los resultados de la estimación del modelo, incluyendo un análisis de intervención para tener en cuenta los efectos del *shock* asociado al coronavirus 2019 (CV19, en adelante). A continuación, se exponen los resultados de dos análisis estructurales: uno centrado en la reducción de la dimensión del sistema y otro diseñado para estimar las elasticidades de las bases tributarias respecto al crecimiento y la inflación. La sexta sección muestra los usos predictivos del modelo, diferenciando entre previsión incondicionada y condicionada, así como el uso de esta última para el diseño de un esquema de previsión en tiempo real. Finalmente, el texto termina con un apartado de conclusiones y un apéndice técnico en el que se detalla el proceso de elaboración del factor CV19, utilizado como variable exógena de intervención en la estimación del modelo BVAR.

2. DATOS

Como ya se ha señalado, el objetivo principal del modelo BVAR es la proyección y análisis de las principales bases tributarias de la economía española. Para ello, se ha seleccionado un conjunto amplio de variables, $k=24$, de forma que están presentes todos sus determinantes macroeconómicos.

nicos: producción, actividad, empleo, precios y salarios, condiciones financieras y monetarias y entorno exterior. La lista de variables seleccionadas se muestra en la siguiente tabla.

Tabla 1
VARIABLES UTILIZADAS

Bloque	Variable	Unidad	Fuente	Frecuencia	Pre-procesamiento	Transformación
Entorno exterior	Tipo de cambio dólar/euro	Dólar por euro (\$/€)	Banco de España	Mensual		log
	Producto Interior Bruto UE	Índice encadenado, valoración monetaria, €	Eurostat	Trimestral	CVEC (*)	log
	Producto Interior Bruto EE.UU.	Índice encadenado, valoración monetaria, \$	U.S. Bureau of Economic Analysis	Trimestral	CVEC	log
Condiciones monetarias y financieras	Tipo de intervención BCE (implícito)	Tasa porcentual	Sitio Internet de J. Cynthia Wu (**)	Mensual		
	Tipo de interés letras 1 año	Tasa porcentual	Banco de España	Mensual		
	Tipo de interés bonos 10 años	Tasa porcentual	Banco de España	Mensual		
	Agregado monetario M2	Euros	Banco de España	Mensual	CVEC, interno	log
Precios	Índice de Precios de Consumo (IPC)	Índice, 2015=100	Instituto Nacional de Estadística	Mensual	CVEC, interno	log
	Precio petróleo Brent (\$)	Precio del barril en dólares	Thomson-Reuters Datastream	Mensual		log
	Índice The Economist materias primas	Índice, 2015=100	The Economist	Mensual		log
	Índice de Precios Industriales (IPRI)	Índice, 2015=100	Instituto Nacional de Estadística	Mensual		log
Demanda y actividad	Producto Interior Bruto (PIB)	Índice encadenado, referencia 2015=100	Instituto Nacional de Estadística	Trimestral	CVEC	log
	Índice de Producción Industrial (IPI)	Índice, 2015=100	Instituto Nacional de Estadística	Mensual	CVEC	log
	Exportaciones de bienes deflactadas	Euros deflactados, base=2005	Agencia Tributaria, Aduanas	Mensual	CVEC	log
	Importaciones de bienes deflactadas	Euros deflactados, base=2005	Agencia Tributaria, Aduanas	Mensual	CVEC	log
	Ventas interiores VESGEP	Euros deflactados, base=2018	Agencia Tributaria, VESGEP	Trimestral	CVEC	log
Mercado de trabajo	Afiliados a la Seguridad Social	Personas	Seguridad Social	Mensual	CVEC	log
	Empleo: horas trabajadas	Horas	Instituto Nacional de Estadística	Trimestral	CVEC	log
	Remuneración por asalariado	Euros	Instituto Nacional de Estadística	Trimestral	CVEC	log
Posición cíclica	Capacidad utilizada en la industria	Porcentaje	M ⁹ Industria	Trimestral		
	Tasa de paro	Porcentaje respecto a la población activa	Instituto Nacional de Estadística	Trimestral	CVEC, interno	
Bases tributarias	Renta bruta de los hogares	Euros	Agencia Tributaria	Trimestral	CVEC, interno	log
	Gasto final sujeto a IVA	Euros	Agencia Tributaria	Trimestral	CVEC, interno	log
	Consumos sujetos a II.EE.	Euros	Agencia Tributaria	Trimestral	CVEC, interno	log

(*) CVEC: Corregido de Variaciones Estacionales y de Calendario

(**) <https://sites.google.com/view/jingynthiawu/shadow-rates>

El modelo BVAR procesa las series en frecuencia trimestral. Si una variable es observada mensualmente, es agregada temporalmente. El intervalo muestral abarca desde 1995:1 hasta 2022:3 ($T=111$) y la fecha de cierre de la base de datos es el 8 de enero de 2023.

Todas las series han sido corregidas de efectos estacionales y de calendario, bien por la propia fuente estadística bien internamente. En este último caso, el ajuste estacional se realiza mediante el programa `X13-ARIMA-SEATS` del U.S. Bureau of the Census (U.S. Census Bureau, 2017) a través de la librería `R seasonal` (Sax y Eddelbuettel, 2018). Si la frecuencia nativa de una serie temporal es mensual, el ajuste estacional y de calendario se lleva a cabo en esa frecuencia.

Todas las series son transformadas logarítmicamente, excepto las que representan valores relativos expresados como porcentajes: tipos de interés, grado de utilización de la capacidad productiva y tasa de paro. Todas las variables del modelo son procesadas en niveles.

La base de datos se articula en torno a seis bloques que representan los principales componentes de la economía española: entorno exterior, condiciones financieras y monetarias, precios, demanda y actividad, mercado de trabajo y bases tributarias.

El bloque que define el entorno exterior de la economía española incluye el Producto Interior Bruto (PIB) de la Unión Europea y el de los Estados Unidos, así como el tipo de cambio nominal del dólar respecto al euro. Estas variables ejercen una influencia teóricamente unidireccional sobre las variables domésticas, como consecuencia del carácter abierto y pequeño de la economía española.

Las condiciones financieras y monetarias tratan de representar, en primer lugar, la curva de tipos de interés de la economía española, representada por sus plazos extremos: el tipo de intervención del Banco Central Europeo (BCE) y el rendimiento interno de los valores del Tesoro español a corto plazo (Letras a un año) y a largo plazo (Bonos a 10 años). Con el fin de tener en cuenta la

instrumentación cuantitativa de la política monetaria, se utiliza el tipo implícito (*shadow*) estimado por Wu y Xia (2017), cuya metodología ofrece una estimación del rango de variación por debajo del límite inferior nulo (ZLB, *Zero Lower Bound*). Para asegurar que los aspectos cuantitativos han sido adecuadamente representados, se ha incluido también el agregado monetario M2 (billetes y monedas en circulación, depósitos a la vista, depósitos a plazo de hasta dos años y los disponibles con preaviso de hasta tres meses).

El contenido de dos de las variables que del bloque de precios se solapa con el de las del entorno exterior: el precio en dólares del petróleo Brent y el índice agregado de materias primas elaborado por *The Economist*. Ambos recogen los niveles de precios de los *inputs* energéticos y productos básicos a nivel mundial. Por el contrario, el índice de precios industriales (IPRI) ofrece una perspectiva doméstica y mayorista de las condiciones inflacionarias de la economía española. El IPRI puede interpretarse como una variable intermedia entre las condiciones inflacionarias globales (petróleo Brent, precio de las materias primas) y las locales y minoristas (IPC, Índice de Precios de Consumo), véase Frutos y Quilis (1999).

El bloque de demanda y actividad incluye dos variables trimestrales básicas: el PIB y las ventas interiores deflactadas de grandes empresas y PYMES societarias (VESGEP). La primera, estimada por la Contabilidad Nacional Trimestral (CNTR) del Instituto Nacional de Estadística (INE), es la referencia estándar de la situación coyuntural de la economía española.

La segunda, VESGEP, proporciona un complemento y contraste de carácter directo⁵. Estas ventas, estimadas por la Agencia Estatal de Administración Tributaria (AEAT), además de su amplia cobertura, pueden ser utilizadas como indicador adelantado mediante su extrapolación a partir de las series mensuales de Grandes Empresas (VESGE) y de las diarias (ventas de las empresas integradas en el sistema de Suministro Inmediato de Información de la AEAT, SII).

Con el fin de aumentar la sensibilidad a la información de corto plazo de este bloque se han incluido también tres indicadores de coyuntura clásicos: el Índice de Producción Industrial (IPI), las exportaciones y las importaciones de bienes, ambas debidamente deflactadas.

El estado del mercado de trabajo viene recogido, desde la óptica de cantidades, por las series de afiliaciones a la Seguridad Social y de horas trabajadas estimadas por la CNTR. Estas dos series se complementan entre sí, midiendo los márgenes extensivo e intensivo de la actividad productiva, respectivamente. Finalmente, la óptica nominal de ese mercado es cuantificada mediante la remuneración por asalariado estimada por la CNTR.

Dos variables forman el bloque de posición cíclica: el porcentaje de utilización de la capacidad productiva en la industria y la tasa de paro, que aproximan el grado de uso de los factores productivos (capital y trabajo, respectivamente), siendo además *inputs* de uso inmediato en las estimaciones de la brecha de producción (*output gap*) de la economía española (Cuerpo *et al.*, 2018).

⁵ Directo en el sentido de que se trata de una fuente estadística basada en la explotación de los registros administrativos, derivados de las declaraciones del Impuesto sobre el Valor Añadido (IVA).

Finalmente, el bloque de bases tributarias está formado por las asociadas a las principales figuras impositivas: renta bruta de los hogares sujeta al Impuesto sobre la Renta de las Personas Físicas (IRPF), gasto final sujeto a IVA y consumo sujeto a Impuestos Especiales (II.EE.)⁶. La base asociada al Impuesto de Sociedades (IS) no ha sido incluida por la dificultad que plantea la obtención de una serie apropiada en frecuencia trimestral. Las bases están valoradas a precios corrientes.

3. MODELO ECONÓMÉRICO

En esta sección se describe el modelo econométrico utilizado, detallando su representación VAR en forma compacta y la estructura de priores empleada que da lugar al modelo BVAR (Sims, 1980; Stock y Watson, 2001; Reinsel, 2003; Lütkepohl, 2005; Tsay, 2014; Blake y Mumtaz, 2015; Miranda-Agrippino y Ricco, 2018).

3.1. Modelo VAR

Sea $Z_t = (z_{1,t} \dots z_{k,t})'$ un vector de observaciones efectuadas sobre k variables en el período t , con $t=1..T$. Se considera que Z_t evoluciona según un modelo vectorial autorregresivo (VAR) de orden p si puede ser expresado de la siguiente forma:

$$[2] \quad Z_t = c + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + U_t$$

donde c es un vector de términos independientes y $\Phi_h, h = 1..p$ son matrices cuadradas de dimensión k . El término U_t representa un *shock* de tipo ruido blanco gaussiano:

$$[3] \quad U_t \sim iid N(0, \Sigma)$$

En general, se asume que Σ no es una matriz diagonal, es decir, que existen interacciones contemporáneas entre las k innovaciones.

Los modelos VAR, definidos por [2] y [3], son estructuras muy generales y flexibles que pueden acomodar representaciones muy distintas, sin necesidad de imponer restricciones *a priori*.

Una representación alternativa de [2] se obtiene mediante su transposición y apilamiento matricial (*matrix stacking*):

$$[4] \quad Z = \begin{bmatrix} 1 & Z_{(1)} & Z_{(2)} & \dots & Z_{(p)} \end{bmatrix} \begin{bmatrix} c' \\ \Phi_1' \\ \Phi_2' \\ \vdots \\ \Phi_p' \end{bmatrix} + U = XB + U$$

Donde Z representa la matriz de $T \cdot p$ observaciones efectivas de las k variables del modelo.

⁶ Los II.EE. se aplican sobre los siguientes bienes: alcohol, cerveza, productos intermedios, hidrocarburos, tabaco, electricidad y carbón.

3.2. Prior y calibrado

El precio a pagar por la flexibilidad y generalidad de los modelos VAR es una tendencia muy acusada a la sobreparametrización y, en consecuencia, al sobreajuste muestral. Este sobreajuste suele tener consecuencias adversas sobre su rendimiento predictivo y sobre la estabilidad de sus estimaciones. Con el fin de resolver estos problemas se ha propuesto en la literatura la introducción de restricciones de forma probabilística o, de manera equivalente, la incorporación de información adicional sobre los parámetros del modelo en un marco bayesiano, dando lugar a los modelos BVAR (Litterman, 1984; Todd, 1984, 1988; Kadiyala y Karlsson, 1997; Karlsson, 2012).

Los modelos BVAR combinan la estructura básica de los VAR, p.e. [4], con un prior que restringe la estimación de sus parámetros. Aplicando el operador de vectorización a [4] se obtiene:

$$[5] \quad y = (I_k \otimes X)\beta + u = x\beta + u$$

El vector de parámetros β está relacionado con las matrices Φ según:

$$[6] \quad \beta = \text{vec}([c \ \Phi_1 \ \Phi_2 \ \dots \ \Phi_p]')$$

Finalmente, la distribución de la innovación u en la ecuación [5] es:

$$[7] \quad u \sim \text{iid } N(0, \Sigma \otimes I_T)$$

La información contenida en un prior puede implementarse añadiendo variables ficticias que replican sus dos primeros momentos. El modelo BVAR que se utiliza en este trabajo incorpora un prior que consta de tres elementos: Minnesota, persistencia propia y persistencia conjunta. A continuación, se exponen los tres de forma resumida.

3.3. Prior de Minnesota

Este prior puede ser aplicado mediante las siguientes variables ficticias:

$$[8] \quad y^M = \begin{bmatrix} 0_{1,k} \\ \frac{1}{\lambda_M} \text{diag}(f_1 s_1^2 \dots f_k s_k^2) \\ 0_{k(p-1),k} \\ \text{diag}(s_1^2 \dots s_k^2) \end{bmatrix}, \quad x^M = \begin{bmatrix} \frac{1}{\lambda_c} & 0_{1, kp-1} \\ 0_{kp,1} & J_p \otimes (\frac{1}{\lambda_M} \text{diag}(s_1^2 \dots s_k^2)) \\ 0_{kp,1} & 0_{kp, kp-1} \end{bmatrix}$$

Siendo:

- λ_M : hiperparámetro que controla de forma global el grado de confianza en el prior de Minnesota (*tightness*). El prior se hace difuso (no informativo) si $\lambda_M \rightarrow \infty$ y estricto si $\lambda_M \rightarrow 0$.
- λ_c : hiperparámetro que cuantifica la concentración del vector de términos independientes en torno a su promedio (cero). Generalmente, se asume un prior difuso para este parámetro, por lo que $\lambda_c \rightarrow \infty$.

- λ_3 : hiperparámetro que define la velocidad de decaimiento (armónico) de la dependencia temporal del prior. Cuanto mayor es, más rápido es dicho decaimiento.
- f_i $i = 1..k$: hiperparámetros que definen el valor medio del prior para la diagonal principal de la matriz Φ_1 . Usualmente, se considera $f_i = 1$ para series expresadas en niveles y $f_i = 0$ para series en primeras diferencias.
- s_i $i = 1..k$: hiperparámetros que definen la escala de las variables. Generalmente, se calibran a partir de los residuos de modelos AR(p) estimados de forma univariante.
- Finalmente, $J_p = \text{diag}(1^{\lambda_3}, 2^{\lambda_3}, \dots, p^{\lambda_3})$ encapsula la función de decaimiento temporal.

En conjunto, el prior de Minnesota [8] refleja una caracterización extramuestral de las series centradas en un vector no acoplado⁷ de paseos aleatorios con deriva, cuya dependencia estática está concentrada en la matriz Σ de varianzas y covarianzas de los *shocks* U_t .

3.4. Prior de persistencia propia (*own-persistence, op*)

Este prior, también denominado de diferenciación inexacta o de suma de coeficientes, está centrado en torno a la siguiente restricción:

$$[9] \quad \Phi_1 + \Phi_2 + \dots + \Phi_p = I_k$$

Su implementación, también mediante variables ficticias, es:

$$[10] \quad y^{op} = \text{diag}\left(\frac{1}{\lambda_{op}}\right)\bar{z} \quad x^{op} = [0 \ y^{op} \ y^{op} \dots \ y^{op}].$$

Siendo \bar{z} el promedio de las p primeras observaciones. El hiperparámetro λ_{op} controla la intensidad de la restricción. El prior deviene difuso (no informativo) si $\lambda_{op} \rightarrow \infty$ y estricto si $\lambda_{op} \rightarrow 0$.

Este prior generaliza al de Minnesota, permitiendo una distribución más flexible de las raíces unitarias del sistema e introduciendo una mayor conexión entre sus parámetros al restringirlos simultáneamente (Doan et al., 1984).

3.5. Prior de persistencia conjunta (*co-persistence, cop*)

Por último, este prior, también denominado de observación inicial, se puede implementar de la siguiente forma, similar al prior de persistencia propia:

$$[11] \quad y^{cop} = \left(\frac{1}{\lambda_{cop}}\right)\bar{z} \quad x^{cop} = [0 \ y^{cop} \ y^{cop} \dots \ y^{cop}].$$

Siendo \bar{z} el promedio de las p primeras observaciones. El hiperparámetro λ_{cop} controla la intensidad de la restricción. El prior deviene difuso (no informativo) si $\lambda_{cop} \rightarrow \infty$ y estricto si $\lambda_{cop} \rightarrow 0$.

⁷ Debido a que el prior asume que Φ_1 es diagonal.

Este prior permite incorporar de forma probabilística que algunas variables del sistema compartan una tendencia común, reflejando una relación de cointegración o equilibrio a largo plazo (Sims, 1993).

El modelo ampliado se forma combinando las observaciones reales y las ficticias, representadas por [5] y [8]-[11], respectivamente.

$$[12] \quad \begin{bmatrix} y \\ y^M \\ y^{op} \\ y^{cop} \end{bmatrix} = \begin{bmatrix} x \\ x^M \\ x^{op} \\ x^{cop} \end{bmatrix} \beta + u^*.$$

Expresando la anterior ecuación en forma compacta:

$$[13] \quad y^* = x^* \beta + u^*.$$

La aplicación del muestreo de Gibbs al modelo [13], asumiendo un prior difuso para sus parámetros, proporciona una estimación de la distribución marginal a posteriori de los parámetros del BVAR: β (que recoge la dinámica del sistema) y Σ (que representa la interacción contemporánea entre las variables y el tamaño de los *shocks* que inciden sobre el mismo).

El calibrado del modelo, esto es, la determinación de los valores apropiados para los hiperparámetros, puede realizarse de diversas formas. En este trabajo se emplea la propuesta de Giannone *et al.* (2015) que considera a los hiperparámetros como parámetros adicionales en un marco *a priori* de tipo jerárquico. En este marco jerárquico se utiliza el algoritmo de Metrópolis como bucle externo (que recorre los hiperparámetros) y el muestreo de Gibbs como bucle interno. De esta forma, se dispone de una estimación bayesiana tanto de los hiperparámetros (λ) como de los parámetros (β y Σ), resolviendo uno de los puntos críticos del proceso de estimación de los BVAR.

4. ESTIMACIÓN Y ANÁLISIS DE INTERVENCIÓN

Las series presentadas en la sección anterior ($k=24$), observadas durante el período 1995:1-2022:3 ($T=111$), sirven de base para la estimación del modelo BVAR definido en la tercera sección, tomando $p=5$ como orden del mismo. Este valor asegura una adecuada representación de la dinámica de las variables consideradas⁸, quedando limitado el riesgo de sobreajuste por la estructura del prior de Minnesota, que constriñe hacia cero la estimación a medida que aumenta el retardo. Todos los resultados han sido obtenidos con los paquetes R `BVAR` (Kuschnig y Vashold, 2020), `BayVAR_R` (Quilis, 2022) y la librería Matlab `FactorLib` (Quilis, 2019).

La muestra disponible está afectada por el *shock* adverso asociado a la crisis sanitaria del CV19. Este *shock*, caracterizado por una intensidad, rapidez en su difusión y extensión sin precedentes en la historia, afecta de manera muy notable a la estimación de los modelos econométricos (Ng,


⁸ Incluyendo “artefactos” eventualmente producidos por el ajuste estacional: autocorrelaciones negativas en los retardos s y $s+1$, siendo s la frecuencia estacional (MARAVALL, 1987).

2020; Lenza y Primiceri, 2020; Primiceri y Tambalotti, 2020; Schorfheide y Song, 2020; Carriero *et al.*, 2021).

El origen epidemiológico del *shock* CV19 así como las medidas administrativas implementadas para contener su extensión, permiten caracterizarlo como exógeno. Esta caracterización se apoya también en la disponibilidad de un calendario preciso de las principales medidas aplicadas. En consecuencia, su tratamiento se adapta muy bien al análisis de intervención (Box y Tiao, 1975).

En este trabajo se utiliza como variable de intervención un factor CV19 estimado para la economía española siguiendo la propuesta de Maroz *et al.* (2021)⁹. En el siguiente gráfico se muestra el factor CV19 estimado para la economía española¹⁰.

Gráfico 1
FACTOR CV19 EN NIVEL DE LA ECONOMÍA ESPAÑOLA



Este factor CV19 muestra un perfil similar al de un atípico de tipo transitorio, marcando una brusca e intensa caída en los dos primeros trimestres de 2020 para revertir a continuación a niveles muy próximos a los anteriores al *shock*.

Este factor puede ser utilizado como una variable de intervención en un modelo BVARX¹¹, posibilitando así la estimación de su impacto en las distintas variables del sistema así como una corrección de las mismas del notable impacto del *shock* CV19 sobre sus niveles.

El modelo planteado es una ampliación de [2] que incluye, como elemento de desplazamiento exógeno, el factor CV19.

$$[14] \quad Z_t = c + \Gamma G_t + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + U_t$$

⁹ En el apéndice A se detalla el procedimiento de estimación del factor CV19 que se utiliza como variable de intervención exógena.

¹⁰ Como se detalla en el apéndice A, el factor representado en el gráfico y utilizado como variable de intervención es el resultado de integrar y agregar temporalmente el factor original (mensual y estacionario) calculado mediante el procedimiento de MAROZ *et al.* (2021).

¹¹ BVARX, donde la X denota “con variables exógenas”.

Siendo:

- G_t : Factor CV19 en niveles.
- Γ : Cargas del factor CV19 sobre las variables observadas.

Con el fin de facilitar la interpretación de las cargas, las variables que intervienen en [14] han sido tipificadas, de manera que sus unidades de medida pueden ser consideradas idénticas. La estimación de Γ se muestra en la siguiente tabla¹².

Tabla 2
ESTIMACIÓN DE LAS CARGAS DEL FACTOR CV19

Variable	Puntual	Estimación	
		d.t.	t-ratio
Capacidad utilizada en la industria	3.14	0.69	4.52
Empleo: Horas trabajadas	2.88	0.41	7.03
Ventas interiores VESGEP	2.14	0.36	6.03
Índice de Producción Industrial (IPI)	2.13	0.40	5.31
Producto Interior Bruto (PIB)	1.93	0.27	7.15
Gasto final sujeto a IVA	1.76	0.32	5.52
Consumos sujetos a II.EE.	1.54	0.27	5.63
Importaciones de bienes deflactadas	1.48	0.27	5.46
Producto Interior Bruto UE	1.45	0.22	6.69
Exportaciones de bienes deflactadas	1.34	0.22	6.22
Precio petróleo Brent (\$)	0.85	0.42	2.03
Producto Interior Bruto EE.UU.	0.83	0.12	6.77
Remuneración por asalariado	0.58	0.10	5.91
Índice de Precios Industriales (IPRI)	0.39	0.13	2.95
Afiliados a la Seguridad Social	0.38	0.07	5.13
Renta bruta de los hogares	0.36	0.08	4.28
Índice The Economist materias primas	0.20	0.35	0.58
Índice de Precios de Consumo (IPC)	0.11	0.05	2.45
Tipo de cambio dólar/euro	0.01	0.40	0.02
Agregado monetario M2	-0.07	0.02	-3.16
Tipo de intervención BCE (Wu-Xia)	-0.07	0.17	-0.40
Tasa de paro	-0.22	0.09	-2.46
Tipo de interés bonos 10 años	-0.23	0.19	-1.24
Tipo de interés letras 1 año	-0.28	0.28	-1.03

La tabla anterior permite apreciar la elevada comunalidad del *shock* CV19, así como su relativa concentración en las variables de actividad y empleo, especialmente en su margen intensivo (horas). Asimismo, el impacto sobre los índices de precios es mucho más contenido y virtualmente nulo sobre los tipos de interés. Las bases tributarias ligadas al IVA y a los impuestos especiales se encuentran dentro de las variables más afectadas por el factor CV19, situándose la renta bruta de los hogares en una posición menos expuesta, posiblemente como resultado de las medidas de sostenimiento del empleo aplicadas.

¹² Por razones de capacidad del software disponible, el modelo utiliza como prior sólo el de Minnesota, calibrado utilizando la muestra pre-CV19 (1995:1-2019:4).

Una vez detraídos los efectos del *shock* CV19 sobre las variables del modelo, se procede a su estimación. Esta estimación incluye como paso esencial la de los hiperparámetros que definen a los tres priores (Minnesota, persistencia propia y persistencia conjunta). La siguiente tabla muestra los resultados para distintas muestras¹³.

Tabla 3
ESTIMACIÓN DE LOS HIPERPARÁMETROS


Muestra	Hiperparámetros			Verosimilitud marginal	Tasa de aceptación	Número de observaciones
	Constricción global	Persistencia				
		Propia	Común			
Pre CV19	0.22	0.49	0.64	4381.06	0.17	100
Completa con corrección CV19	0.22	0.45	0.57	4697.97	0.18	111

Se aprecia la elevada robustez a la muestra de la estimación del hiperparámetro que caracteriza al prior de Minnesota, indicando un grado de constricción relativamente alto. El prior de persistencia propia resulta menos informativo que el de Minnesota aunque también robusto a la muestra.

Finalmente, el prior de persistencia conjunta es el más difuso de los tres y el menos robusto. Este resultado puede ser debido a que, desde una perspectiva global, las series son heterogéneas en su comportamiento a largo plazo, detectándose relaciones de cointegración parciales que involucren a un número relativamente reducido de variables.

La distribución de los hiperparámetros generada por el algoritmo de Metropolis es muy ilustrativa de estas características, como se observa en el gráfico siguiente.

Gráfico 2
DENSIDAD DE LOS HIPERPARÁMETROS



¹³ El algoritmo de Metrópolis ha utilizado 15,000 simulaciones, siendo descartadas las 5,000 primeras (*burn-in sample*).

Un elemento muy importante de la estimación de los parámetros del modelo BVAR es la relativa a la matriz de varianzas y covarianzas de las innovaciones, Σ . Uno de los efectos más notables del *shock* CV19 es la gran distorsión que produce sobre su estimación, mostrando un notable aumento de la volatilidad de las innovaciones y, por lo general, un incremento de sus correlaciones, dada la elevada comunalidad que ha tenido el *shock* CV19 sobre casi todas las variables del sistema. Esta distorsión tiene un efecto muy negativo sobre los intervalos de confianza asociados a las predicciones, ampliándolos de forma inconsistente con la evidencia histórica pre-CV19.

La siguiente tabla muestra las ratios de la diagonal principal de la estimación de Σ con y sin corrección por el factor CV19, ambas respecto a la estimación de Σ utilizando la muestra pre-CV19.

Tabla 4

RATIO DE LA DIAGONAL DE Σ RESPECTO A SU ESTIMACIÓN PRE-CV19, CON Y SIN AJUSTE POR EL FACTOR CV19

	Con ajuste	Sin ajuste
Tipo de cambio dólar/euro	0.97	0.98
Producto Interior Bruto UE	1.26	6.17
Producto Interior Bruto EE.UU.	1.15	3.46
Tipo de intervención BCE (implícito)	1.40	1.40
Tipo de interés letras 1 año	0.93	0.96
Tipo de interés bonos 10 años	1.03	1.06
Agregado monetario M2	0.99	1.07
Índice de Precios de Consumo (IPC)	1.21	1.24
Precio petróleo Brent (\$)	0.99	1.26
Índice The Economist materias primas	1.12	1.14
Índice de Precios Industriales (IPRI)	1.84	2.11
Producto Interior Bruto (PIB)	2.24	15.25
Índice de Producción Industrial (IPI)	1.27	3.79
Exportaciones de bienes deflactadas	1.03	2.19
Importaciones de bienes deflactadas	1.06	2.22
Ventas interiores VESGEP	1.08	3.04
Afiliados a la Seguridad Social	1.12	1.52
Empleo: horas trabajadas	1.55	8.98
Remuneración por asalariado	1.15	2.04
Capacidad utilizada en la industria	1.18	1.66
Tasa de paro	1.25	1.16
Renta bruta de los hogares	0.95	1.36
Gasto final sujeto a IVA	1.02	2.21
Consumos sujetos a II.EE.	1.18	2.83

Se aprecia la notable corrección efectuada, especialmente en algunas variables como el PIB o las horas trabajadas, así como una cierta evidencia de que, aún después de ajustar por el factor CV19, la volatilidad de las innovaciones ha aumentado por lo general.

5. ANÁLISIS ESTRUCTURAL


El modelo BVAR permite realizar diversos análisis orientados a caracterizar su estructura latente. En esta sección se realizan dos: una reducción de la dimensión y una aplicación de la metodología de funciones de respuesta a los impulsos. Dado el carácter estructural de este tipo de análisis se utiliza la muestra pre-COVID 1995.1-2019.4.

5.1. Reducción de la dimensión

El primero de los análisis estructurales consiste en aplicar técnicas de reducción de la dimensión al modelo BVAR estimado. Siguiendo a Tiao *et al.* (1993), se especifica y estima un modelo factorial para las series de los residuos del modelo, con el fin de identificar los *shocks* subyacentes que determinan el comportamiento de las innovaciones que afectan a cada una de las 24 variables del sistema. De esta manera se explora en qué medida estos *shocks* poseen elementos comunes y si es posible especificar una estructura simplificada para los mismos.

La estructura de autovalores de los residuos del modelo, tanto de la sección cruzada completa ($k=24$) como de la ampliada de forma recursiva, sugiere un número reducido de factores comunes, $r=2$ o $r=3$, para representar a los *shocks* primarios o básicos del sistema. El comportamiento explosivo de los tres primeros autovalores que se aprecia en el siguiente gráfico así lo indica.

Gráfico 3
AUTOVALORES DE LA MATRIZ DE CORRELACIONES DE LOS RESIDUOS
ESTIMACIÓN RECURSIVA SOBRE LA SECCIÓN CRUZADA



Como se aprecia en la tabla siguiente, la estructura de aglomeración de las variables en los dos primeros factores comunes sugiere la presencia de un factor común dominante de carácter pro-

cíclico, especialmente relevante para las variables reales (PIB, demanda agregada, empleo) pero que también es importante para las nominales (precios de las materias primas, IPRI, IPC)¹⁴.

Tabla 5
CARGAS DE LAS VARIABLES EN LOS FACTORES

Bloque	Variable	Cargas		Comunalidad		Total
		Factor 1	Factor 2	Factor 1	Factor 2	
Entorno exterior	Tipo de cambio dólar/euro	0.73	-0.33	0.53	0.11	0.64
	Producto Interior Bruto UE	0.56	0.48	0.31	0.23	0.54
	Producto Interior Bruto EE.UU.	-0.25	0.06	0.06	0.00	0.06
Condiciones monetarias y financieras	Tipo de intervención BCE (Wu-Xia)	0.83	-0.11	0.68	0.01	0.69
	Tipo de interés letras 1 año	0.50	0.13	0.25	0.02	0.27
	Tipo de interés bonos 10 años	0.59	0.14	0.34	0.02	0.36
	Agregado monetario M2	0.40	0.44	0.16	0.20	0.36
Precios	Índice de Precios de Consumo (IPC)	0.27	0.61	0.07	0.37	0.44
	Precio petróleo Brent (\$)	-0.06	-0.21	0.00	0.04	0.05
	Índice The Economist materias primas	0.67	0.43	0.45	0.18	0.63
	Índice de Precios Industriales (IPRI)	0.71	0.23	0.50	0.05	0.55
Demanda y actividad	Producto Interior Bruto (PIB)	0.61	0.46	0.37	0.21	0.58
	Índice de Producción Industrial (IPI)	0.83	-0.08	0.69	0.01	0.70
	Exportaciones de bienes deflactadas	0.71	0.06	0.50	0.00	0.50
	Importaciones de bienes deflactadas	0.63	-0.24	0.39	0.06	0.45
	Ventas interiores VESGEP	0.56	-0.50	0.32	0.25	0.57
Mercado de trabajo	Afiliados a la Seguridad Social	0.55	-0.26	0.30	0.07	0.37
	Empleo: horas trabajadas	0.28	-0.39	0.08	0.15	0.23
	Remuneración por asalariado	0.18	-0.27	0.03	0.07	0.11
Posición cíclica	Capacidad utilizada en la industria	0.24	0.21	0.06	0.04	0.10
	Tasa de paro	-0.57	0.38	0.32	0.15	0.47
Bases tributarias	Renta bruta de los hogares	0.34	-0.45	0.11	0.20	0.31
	Gasto final sujeto a IVA	0.43	-0.37	0.18	0.14	0.32
	Consumos sujetos a II.EE.	0.52	0.16	0.27	0.03	0.30


El segundo factor es muy relevante para establecer un contraste entre series reales y nominales, aunque su capacidad explicativa es claramente inferior a la del primero.

Utilizando la matriz de puntuaciones (*scores*) derivada del modelo factorial de los *shocks* de la forma reducida, se puede reducir directamente la dimensión del vector de series observadas. Esta matriz es aplicada a la muestra completa de las series corregidas del factor CV19, normalizadas para asegurar la consistencia con el análisis factorial.

De esta manera, se obtiene un índice que representa la tendencia común del sistema, tal y como puede apreciarse en el siguiente gráfico.

¹⁴ La limitada capacidad explicativa del tercer factor y la ausencia de una pauta clara de aglomeración de las variables en el mismo, han llevado a limitar a dos el número de factores latentes.

Gráfico 4
FACTOR TENDENCIAL COMÚN¹⁵



Si se compara esta serie con el fechado cíclico de la economía española elaborada por la Asociación Española de Economía (AEE)¹⁶, se aprecia una conformidad global entre sus puntos de giro.

Esta tendencia común combina información real y nominal, por lo que no puede ser considerada como una medida de producto potencial. Adicionalmente, muestra un notable truncamiento a la baja a comienzos de 2008 que da lugar a una evolución lateral hasta 2015, momento en el que retoma su perfil ascendente inicial. Esta segunda etapa está puntuada por el *shock* CV19, aunque de forma muy limitada¹⁷, y está claramente influida por el impulso inflacionario iniciado en 2021.


Análogamente, se puede estimar una medida de posición cíclica global asociada al segundo factor de los *shocks* de la forma reducida. La conformidad con el fechado de la AEE es sustancialmente menor, lo que lleva a considerar que dicho fechado está centrado en un concepto de ciclo en niveles (ciclo clásico).

¹⁵ Estimado a partir de las series corregidas del efecto del factor CV19.

¹⁶ <http://www.asesec.org/CFCweb/index.php/archivo-historico-del-ciclo-economico-espanol/>.

¹⁷ Recuérdese que la transformación derivada del análisis factorial se ha aplicado a las series corregidas del efecto del factor CV19, por lo que esta pequeña oscilación es debida más a una combinación de elementos idiosincrásicos que al movimiento común que experimentaron como consecuencia del shock CV-19. Así, esta oscilación tiene una amplitud similar a otras como, por ejemplo, la de mediados de 2021.

Gráfico 5
FACTOR CÍCLICO COMÚN¹⁸



5.2. Elasticidades de las bases tributarias

Por su naturaleza, las bases tributarias responden a una multiplicidad de impulsos, tanto reales como nominales. Esta respuesta o elasticidad, así como una medida de la incertidumbre asociada a su estimación, es esencial para la planificación tributaria y presupuestaria.

En esta sección se presenta una estimación de estas elasticidades basada en el mismo procedimiento empleado para generar predicciones condicionadas (Robertson y Tallman, 1999). El algoritmo utilizado es el siguiente¹⁹:

- Proyección incondicionada de la base (B) y del PIB (Y). Se considera un horizonte de predicción de 12 trimestres.
- Condicionamiento: la proyección del PIB es desplazada de forma que su crecimiento anual es un 1% mayor durante cada uno de los 12 trimestres: Y^* . Este es el impulso.
- Proyección condicionada de la base (B^*).
- Elasticidad: $e = \frac{B^*/B}{Y^*/Y}$, para cada trimestre de los tres años predichos.

Naturalmente, el algoritmo puede ser adaptado para otra variable, distintos horizontes u otras variaciones porcentuales.

Técnicamente, este algoritmo equivale a un análisis basado en la función de impulso-respuesta generalizada (Pesaran y Shin, 1998), ya que el desplazamiento del PIB es el resultado de una combinación no identificada de *shocks*. Una importante ventaja de este enfoque radica en que

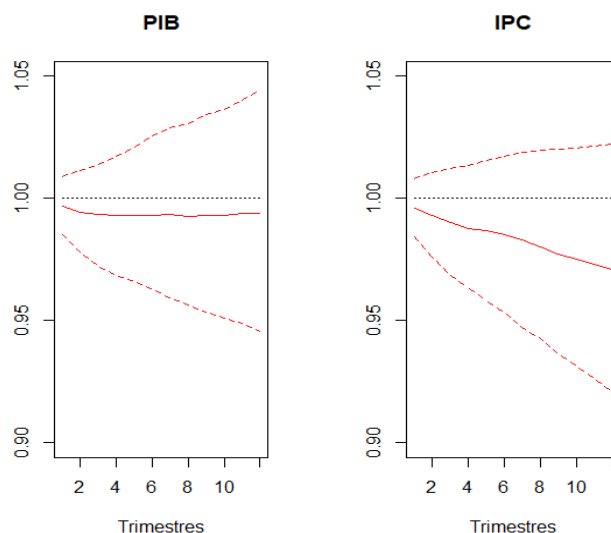
¹⁸ Estimado a partir de las series corregidas del efecto del factor CV19.

¹⁹ Se toma como referencia el PIB aunque el procedimiento puede ser aplicado para cualquier variable.

examina la relación entre las variables observables sobre las que se diseñan escenarios y se formulan predicciones de forma directa.

En el siguiente gráfico se examina la elasticidad de la renta bruta de los hogares respecto al PIB (impulso real) y al IPC (impulso nominal). Se representa temporalmente tanto la respuesta mediana como el intervalo de confianza asociado a una masa de probabilidad del 68%, asumiendo normalidad.

Gráfico 6
ELASTICIDADES DE LA RENTA BRUTA DE LOS HOGARES



Se aprecia la relativa constancia en el tiempo de la elasticidad respecto al PIB así como su proximidad a un valor unitario, aunque sistemáticamente inferior a dicho valor. Por su parte, la elasticidad respecto al IPC también es inicialmente próxima a uno, pero va haciéndose menos intensa a medida que transcurre el tiempo.

Como puede apreciarse en las dos tablas siguientes, este patrón cualitativo se reproduce en las dos elasticidades de la base del IVA y en la de los Impuestos Especiales sólo con respecto al PIB, siendo mucho más estable y próxima a la unidad la que tiene esta última base respecto al IPC:

Tabla 6
ELASTICIDAD DE LAS BASES RESPECTO AL PIB

Horizonte	Renta bruta de los hogares			Gasto final sujeto a IVA			Consumos sujetos a II.EE.		
	Inf.	Mediana	Sup.	Inf.	Mediana	Sup.	Inf.	Mediana	Sup.
1	0.99	1.00	1.01	0.98	1.00	1.03	0.98	1.00	1.02
2	0.98	0.99	1.01	0.97	1.00	1.03	0.97	1.00	1.03
3	0.97	0.99	1.01	0.96	1.00	1.04	0.96	1.00	1.03
4	0.97	0.99	1.02	0.95	1.00	1.05	0.96	1.00	1.04
5	0.97	0.99	1.02	0.95	1.00	1.05	0.95	1.00	1.04
6	0.96	0.99	1.03	0.95	1.00	1.06	0.95	1.00	1.05
7	0.96	0.99	1.03	0.95	1.00	1.06	0.94	0.99	1.05
8	0.96	0.99	1.03	0.94	1.00	1.07	0.94	1.00	1.06
9	0.95	0.99	1.03	0.94	1.01	1.07	0.94	1.00	1.06
10	0.95	0.99	1.04	0.94	1.00	1.07	0.93	1.00	1.06
11	0.95	0.99	1.04	0.93	1.00	1.08	0.93	1.00	1.07
12	0.95	0.99	1.04	0.93	1.00	1.08	0.93	1.00	1.07

La tabla siguiente muestra los cálculos de las elasticidades tomando el IPC como variable impulsora.

Tabla 7
ELASTICIDAD DE LAS BASES RESPECTO AL IPC

Horizonte	Renta bruta de los hogares			Gasto final sujeto a IVA			Consumos sujetos a II.EE.		
	Inf.	Mediana	Sup.	Inf.	Mediana	Sup.	Inf.	Mediana	Sup.
1	0.98	1.00	1.01	0.97	1.00	1.02	0.98	1.00	1.02
2	0.98	0.99	1.01	0.96	0.99	1.03	0.97	1.00	1.03
3	0.97	0.99	1.01	0.95	0.99	1.03	0.97	1.00	1.04
4	0.96	0.99	1.01	0.94	0.99	1.03	0.96	1.00	1.04
5	0.96	0.99	1.02	0.93	0.98	1.04	0.96	1.00	1.05
6	0.95	0.99	1.02	0.93	0.98	1.04	0.95	1.00	1.05
7	0.95	0.98	1.02	0.92	0.98	1.04	0.95	1.00	1.06
8	0.94	0.98	1.02	0.91	0.97	1.04	0.95	1.00	1.06
9	0.94	0.98	1.02	0.90	0.97	1.04	0.95	1.00	1.06
10	0.93	0.97	1.02	0.90	0.97	1.04	0.94	1.00	1.07
11	0.93	0.97	1.02	0.89	0.96	1.04	0.94	1.00	1.07
12	0.92	0.97	1.02	0.88	0.96	1.04	0.94	1.00	1.07

6. PREDICCIÓN

El uso principal del modelo BVAR es la generación de predicciones de las bases tributarias ligadas al IRPF, al IVA y a los II.EE. de una forma consistente y simultánea con sus determinantes macroeconómicos (producción, actividad, empleo, precios y salarios, condiciones financieras y monetarias y entorno exterior). A continuación, se exponen los dos modos de predicción complementarios.


6.1. Predicción incondicionada

El primer tipo de predicción es la incondicionada, que resulta de la proyección de la ecuación en diferencias vectorial del modelo BVAR tomando como condición inicial la última observación disponible de Z_t . Esta proyección permite construir un escenario inercial o central resultado de la dinámica histórica del sistema.

La naturaleza del modelo BVAR y su estimación numérica permiten construir intervalos de confianza²⁰ que pueden ser utilizados como sendas de control, determinando *ex post* en qué medida los valores efectivamente observados se sitúan dentro del rango esperado o fuera del mismo, en cuyo caso estarían indicando la presencia de innovaciones (positivas o negativas) que alteran el escenario inicial.

El siguiente gráfico muestra el caso de la base ligada al IRPF para el intervalo 2022:4-2023:4. Se incluye, como referencia, la serie corregida del factor CV19.

Gráfico 7
PREDICCIÓN INCONDICIONADA DE LA RENTA BRUTA DE LOS HOGARES



6.2. Predicción condicionada

La predicción condicionada permite contestar preguntas del tipo “¿qué crecimiento real e inflación son consistentes con unas proyecciones dadas de las bases tributarias?”. De esta forma, es posible evaluar la consistencia y realismo de previsiones presupuestarias externas.

Tomando de nuevo la renta bruta de los hogares, se asume una trayectoria trimestral para 2023 compatible con un crecimiento dado (p.e. del 6,5%)²¹. Esta trayectoria es condicionante para la proyección de las 23 variables restantes, entre ellas el PIB y el IPC que servirán para cuantificar el ritmo de crecimiento agregado y la tasa de inflación, respectivamente.

La siguiente tabla compara las previsiones incondicionales con las condicionadas, incluyendo un intervalo de confianza que contiene una masa de probabilidad del 68%.

²⁰ En general, lo que se estima es una densidad probabilística conjunta de todas las variables incluidas en el modelo BVAR.

²¹ La senda trimestral se obtiene aplicando métodos de desagregación temporal (Denton), tomando como referencia anual el nivel asociado al crecimiento del 6,5% y, como indicador trimestral, la proyección incondicionada. En este ejercicio se asume el año 2022 como cerrado con la predicción incondicionada de 2022:4.

Tabla 8
PREVISIÓN CONDICIONADA DEL PIB Y EL IPC A UNA BASE TRIBUTARIA

Variable	2022	2023			
		Incondicional	Mediana	Condicionada	
				Inf.	Sup.
Producto Interior Bruto (PIB)	5.06	1.06	1.23	-1.18	3.65
Índice de Precios de Consumo (IPC)	7.75	5.88	5.93	3.90	8.05
Renta bruta de los hogares	5.99	4.90	6.50		

Se aprecia que el crecimiento real y la inflación compatibles con un escenario externo de la base tributaria considerada, son ambos superiores a los correspondientes a la previsión incondicionada. No obstante, la gran amplitud de los intervalos de confianza generados los hace probabilísticamente consistentes con las proyecciones inerciales. Esta elevada incertidumbre se debe al notable incremento de la volatilidad de las innovaciones, incluso después de corregir por el factor CV19.

6.3. Esquema de predicción en tiempo real

La predicción condicionada permite diseñar un esquema operativo de predicción en tiempo real para el modelo BVAR utilizado. La presencia en la base de datos de series de frecuencia mensual ofrece una cobertura de los últimos trimestres más completa que la que ofrecen las series trimestrales.

El esquema propuesto consiste en condicionar las predicciones a los valores observados de las series para las que la cobertura del último trimestre es completa. De esta manera, se asegura el uso más completo posible de la información disponible, así como garantizar que el comienzo del algoritmo de predicción está adecuadamente centrado en datos ya observados.

La siguiente tabla muestra un esquema simplificado, considerando dos tipos de series: las observadas hasta el cuarto trimestre del año T (Z_1) y las que lo son hasta el trimestre anterior (Z_2). Las primeras actúan como variables condicionantes sólo para el cuarto trimestre y se derivan predicciones condicionadas tanto para Z_1 como para Z_2 en los intervalos $[T+1:1, T+1:4]$ y $[T, T+1:4]$, respectivamente.

Tabla 9
PREDICCIÓN EN TIEMPO REAL MEDIANTE PREDICCIÓN CONDICIONADA

	T				T+1				
	1	2	3	4	1	2	3	4	
Z_1	Dato observado				Dato condicionante				Dato observado
Z_2	Dato observado			Dato condicionante				Predicción condicionada	

7. CONCLUSIONES

El modelo BVAR utilizado en este trabajo ofrece un procedimiento operativo para proyectar las bases tributarias de una manera flexible, objetiva y estadísticamente fundamentada.

En comparación con otros enfoques econométricos, resuelve tanto los problemas de especificación dinámica como de simultaneidad entre las variables consideradas. Asimismo, permite incorporar relaciones de cointegración de una manera flexible y guiada por los datos. Esto es especialmente importante en el contexto económico actual, caracterizado desde 2007 por la presencia de fuertes *shocks* de naturaleza muy diversa: financiera (2008), epidemiológica (2020) y de oferta (2022).

En este sentido, la metodología utilizada para tratar el impacto del *shock* CV19 ha resultado satisfactoria, ofreciendo una cuantificación del mismo y una evidencia que apunta hacia un aumento persistente de la volatilidad de los *shocks* que inciden sobre el sistema económico.

Por otra parte, el uso de las predicciones condicionadas proporcionadas por el modelo es especialmente importante para el análisis estructural (p.e. cálculo de elasticidades), la evaluación de predicciones externas o la eventual generación de escenarios de estrés.

Técnicamente, la posibilidad de estimar los hiperparámetros que caracterizan al prior dentro del mismo procedimiento que los parámetros del VAR (β y Σ) resuelve uno de los puntos más controvertidos de los modelos BVAR de una manera coherente y práctica.

Como futuros desarrollos se considera el pre-procesamiento de la base del IS para poder modelizarla en frecuencia trimestral de la misma forma que las restantes bases y la identificación de relaciones de cointegración mediante análisis canónico (Box y Tiao, 1977).

Bibliografía

- BLAKE, A. y MUMTAZ, H. (2015): "Applied Bayesian Econometrics for Central Bankers", Centre for Central Banking Studies, Bank of England, *Handbooks* n. 36.
- BOX, G. E. P. y TIAO, G. C. (1975): "Intervention Analysis with Applications to Economic and Environmental Problems", *Journal of the American Statistical Association*, 70, 70-79.
- BOX, G. E. P. y TIAO, G. C. (1977): "A Canonical Analysis of Multiple Time Series", *Biometrika*, 64, 355-365.
- CARRIERO, A.; CLARK, T.; MARCELLINO, M. y MERTENS, E. (2021): "Addressing COVID-19 Outliers in BVARs with Stochastic Volatility", SSRN Working Paper.
- CUERPO, C., CUEVAS, A. y QUILIS, E. M. (2018): "Estimating Output Gap: a Beauty Contest Approach", *SERIEs*, 9, 275-304.
- CUEVAS, A.; PÉREZ-QUIRÓS, G. y QUILIS, E. M. (2017): "Integrated Model of Short Term Forecasting of the Spanish Economy (MIPRED model)", *Revista de Economía Aplicada*, 25, p. 5-25.
- CUEVAS, A.; LEDO, R. y QUILIS, E. M. (2019): "Incorporando información fiscal de frecuencia diaria en la previsión macroeconómica a corto plazo", *Papeles de Trabajo*, n. 11/2019, Instituto de Estudios Fiscales.
- DOAN, T.; LITTERMAN, R. B. y SIMS, C. A. (1984): "Forecasting and Conditional Projection using Realistic Prior Distributions", *Econometric Review*, 3, 1-144.
- FRUTOS, R. y QUILIS, E. M. (1999): "Características inflacionarias de la economía española: un análisis ARMA vectorial", *Papeles de Trabajo*, nº 9/1999, Instituto de Estudios Fiscales.

- FRUTOS, R.; MELIS, F.; DE LA OSSA, M. J. y RAMOS, J. L. (2003): "La medida de los ingresos públicos en la Agencia Tributaria. Caja, derechos reconocidos y devengo económico", *Papeles de Trabajo*, nº 20/2003, Instituto de Estudios Fiscales.
- GIANNONE, D.; LENZA, M. y PRIMICERI, G. E. (2015): "Prior Selection for Vector Autoregressions", *The Review of Economics and Statistics*, 97(2), 436-451.
- KADIYALA, K. R. y KARLSSON, S. (1997): "Numerical Methods for Estimation and Inference In Bayesian VAR Models", *Journal of Applied Econometrics*, 12, 99-132.
- KARLSSON, S. (2012): "Forecasting with Bayesian Vector Autoregressions", University of Örebro, *Working Paper* n. 12/2012.
- KUSCHNIG, N. y VASHOLD, L. (2020): "BVAR: Hierarchical Bayesian Vector Autoregression", R package version 1.0.0., CRAN Repository.
- LENZA, M. y PRIMICERI, G. (2020): "How to Estimate a VAR after March 2020", *Working Paper* n. 2461, Northwestern University, European Central Bank.
- LITTERMAN, R. B. (1984): "Forecasting and Policy Analysis with Bayesian Vector Autoregression Models", Federal Reserve Bank of Minneapolis, *Quarterly Review*, 8(4), 30-41.
- LITTERMAN, R. B. (1986): "Forecasting with Bayesian Vector Autoregressions: five years of experience", *Journal of Business and Economic Statistics*, 4(1), 25-38.
- LÜTKEPOHL, H. (2005): *New Introduction to Multiple Time Series Analysis*, Springer.
- MARAVALL, A. (1987): "Descomposición de series temporales: especificación, estimación e inferencia", *Estadística Española*, 1(14), 1-19.
- MARÓZ, D.; STOCK, J. H. y WATSON, M. W. (2021): "Comovement of Economic Activity during the Covid Recession", International Institute of Forecasters, International Symposium, Madrid, Diciembre.
- MIRANDA-AGRIPPINO, S. y RICCO, G. (2018): "Bayesian Vector Autoregressions", *Working Paper* n. 756, Bank of England.
- NG, S. (2021): "Modeling Macroeconomic Variations after Covid-19", *NBER Working Paper*, n. 29060.
- PESARAN, M. H. y SHIN, Y. (1998): "Generalized Impulse Response Analysis in Linear Multivariate Models", *Economics Letters*, 58, 17-29.
- PRIMICERI, G. y TAMBALOTTI, A. (2020): "Macroeconomic Forecasting at the Time of COVID-19", *Working Paper*, Northwestern University.
- QUILIS, E. M. (2019): "FactorLib: A MATLAB Library for Static Factor Analysis", *SSRN Working Paper*.
- QUILIS, E. M. (2022): "BayVAR_R: Bayesian VAR modeling in R", *SSRN Working Paper*.
- QUILIS, E. M. y FRUTOS, R. (2020): "Un análisis dinámico de la distribución salarial en España", *Papeles de Trabajo* nº 3/2020, Instituto de Estudios Fiscales.
- REINSEL, G. (2003): *Elements of Multivariate Time Series Analysis*, Springer.
- ROBERTSON, J. C. y TALLMAN, E. W. (1999): "Vector Autoregressions: Forecasting and Reality", Federal Reserve Bank of Atlanta, *Economic Review*, Q1, 4-18.
- SAX, C. y EDELBUETTEL, D. (2018): "Seasonal Adjustment by X-13ARIMA-SEATS in R", *Journal of Statistical Software*, 87(11), 1-17.

- SCHORFHEIDE, F. y SONG, D. (2020): "Real Time Forecasting with a (Standard) Mixed-Frequency VAR during a Pandemic", *NBER Working Paper* n. 29535.
- SIMS, C. A. (1980): "Macroeconomics and reality", *Econometrica*, 48(1), 1-48.
- SIMS, C. A. (1993): "A Nine-variable Probabilistic Macroeconomic Forecasting Model", en National Bureau of Economic Research (Ed.), *Business Cycles, Indicators and Forecasting*, 179-212.
- STOCK, J. H. y WATSON, M. W. (2001): "Vector Autoregressions", *Journal of Economic Perspectives*, 15(4), 101-115.
- TIAO, G. C.; TSAY, R. S. y WANG, T. (1993): "Usefulness of linear transformations in multivariate time series analysis", *Empirical Economics*, 18(4), 567-93.
- TODD, R. M. (1984): "Improving Economic Forecasting with Bayesian Vector Autoregressions", *Quarterly Review*, 8(4), 18-29, Federal Reserve Bank of Minneapolis.
- TODD, R. M. (1988): "Implementing Bayesian Vector Autoregressions", *Working Paper* n. 384, Federal Reserve Bank of Minneapolis.
- TSAY, R. S. (2014): *Multivariate Time Series Analysis*, John Wiley & Sons.
- U. S. CENSUS BUREAU, TIME SERIES RESEARCH STAFF (2017): "X-13ARIMA-SEATS Reference Manual", U.S. Census Bureau Reference Manual.
- WU, J. C. y XIA, F. (2017): "Time-Varying Lower Bound of Interest Rates in Europe", *Chicago Booth Research Paper* n. 17-06.

APÉNDICE A: ESTIMACIÓN MULTIVARIANTE DEL SHOCK CV19

Recientemente, Maroz, Stock y Watson (2021), MSW en adelante, han desarrollado una metodología para estimar, mediante un modelo factorial dinámico (MFD), un “factor CV19”. Las principales características de este factor son:

- Representa la evolución *conjunta* de los indicadores considerados en el modelo después del *shock* CV19 a partir de 2020:03.
- Comprende tanto la etapa inicial (ligada fundamentalmente a las medidas de confinamiento, con fechas de inicio y fin bien definidas) como a la subsiguiente etapa, mucho más heterogénea tanto en lo que concierne a medidas como a la propia respuesta endógena de la economía.
- Este factor CV19 se identifica y estima con independencia de los factores comunes que habitualmente gobiernan la dinámica de los indicadores, por lo que se le atribuye un carácter esencialmente atípico y exógeno.
- Finalmente, este factor CV19 es también independiente de los factores específicos de cada variable.

Esta metodología, además de ser relativamente sencilla y encajar muy bien con la caracterización esencialmente exógena del *shock* CV19, permite estimar su impacto en un vector de series temporales, identificando las series más y menos afectadas por dicho *shock*, así como el perfil temporal del propio factor CV19. A continuación, se describe el procedimiento MSW.

Modelo

- Factorial dinámico, con $r=3$ factores.
- Frecuencia: mensual.
- Muestra completa: 1959:03–2021:10 ($T=751$)
 - Submuestra pre-CV19: 1959:03–2020:02 ($T_0=731$, ~97% respecto a T).
 - Post-CV19: 2020:03–2021:10 ($T_1=20$, ~3% respecto a T).
- Indicadores:
 - Elementales: $k=89$, con los que se estima el MFD.
 - Agregados: $k_1=38$, que se relacionan con los elementales mediante modelos de regresión lineal (p.e. el IPI general con los IPIs elementales, las ventas totales con las ventas por destino económico, etc.).
 - Economía: Estados Unidos.

Pre-procesamiento

- Ajuste estacional y de calendario:
 - $x_{i,t} = x_{i,t}^{sac} \quad i = 1..k; t = 1..T$
- Log-diferenciación o diferenciación:
 - $z_{i,t} = (1 - B)\log(x_{i,t}^{sac}) \quad i = 1..k; t = 1..T$
 - $z_{i,t} = (1 - B) x_{i,t}^{sac} \quad i = 1..k; t = 1..T$
- Corrección de atípicos en la submuestra pre-CV19: los grandes atípicos (superiores a 3.5σ en valor absoluto) son considerados como observaciones ausentes, lo que equivale a tratarlos como atípicos aditivos.
- Corrección de atípicos en la submuestra post-CV19: ninguna.
- Normalización en la submuestra pre-CV19:
 - Eliminación de la media (centrado): la media no es una constante sino una serie que puede evolucionar suavemente. El procedimiento MSW la estima mediante una media móvil (MM) simétrica de gran tamaño (100 términos)²²:
 - $m_{i,t} = \frac{1}{a} \sum_{h=-a}^{h=a} z_{i,t+h} \quad i = 1..k; t = (1+a)..(T_0 - a)$
 - $z_{i,t}^c = z_{i,t} - m_{i,t} \quad i = 1..k; t = 1..T_0$
 - Tipificación: se dividen los valores centrados por la desviación típica de la submuestra pre-CV19:
 - $y_{i,t} = \frac{z_{i,t}^c}{\sigma_i} \quad i = 1..k; t = 1..T_0$
- Normalización en la submuestra post-CV19:
 - Eliminación de la media: se considera la última media calculada pre-CV19:
 - $z_{i,t}^c = z_{i,t} - m_{i,T_0} \quad i = 1..k; t = T_0 + 1..T$
 - Tipificación: se dividen los valores centrados de la forma anterior por la desviación típica pre-CV19.
 - $y_{i,t} = \frac{z_{i,t}^c}{\sigma_i} \quad i = 1..k; t = T_0 + 1..T$
- Signo pro- o anticíclico: las series que *a priori* se consideran anticíclicas (p.e., número de desempleados) son cambiadas de signo):
 - $z_{i,t} = \begin{cases} z_{i,t} & i \in [Procíclicas] \\ -z_{i,t} & i \in [Anticíclicas] \end{cases} \quad t = 1..T$

²² El procedimiento MSW asume una versión asimétrica a medida que t se aproxima a los extremos de la serie.

La siguiente tabla resume estas operaciones, diferenciando la submuestra sobre la que se aplica, pre-CV19 o post-CV19.

Tabla A.1
OPERACIONES DE PRE-PROCESAMIENTO EN EL PROCEDIMIENTO MSW

Operación	Pre-CV19	Post-CV19	Notas
Ajuste estacional y de calendario		Sí	Corrección final para la muestra completa.
Log-diferenciación		Sí	No se incluyen indicadores cualitativos.
Corrección de atípicos	Sí	No	Implícitamente, son atípicos aditivos.
Centrado	Sí	Sí, usando el valor de la media local de 2020:02	La MM(100) se vuelve asimétrica en los extremos
Tipificación	Sí	Sí, usando el valor de la desviación típica pre-CV19	
Signo		Sí	Cambio de signo de las series anticíclicas

Modelo factorial dinámico (MFD)

El MFD que utilizado en el procedimiento MSW es:

$$[A.1] \quad Y_t = \Lambda F_t + \Gamma G_t + U_t \quad t = 1..T$$

Siendo:

- Y : un vector de k series formadas por las primeras diferencias de las series ajustadas de variaciones estacionales y de calendario (posiblemente log-transformadas), corregidas de atípicos (que se tratan como valores ausentes), centradas y tipificadas de forma distinta para los valores de la submuestra pre- y post-CV19. $k=89$.
- F : un vector de $r < k$ factores comunes inobservables, responsables de la dinámica conjunta de las variables observadas. En su aplicación, MSW consideran $r=3$.
- Λ : matriz $k \times r$ de cargas (*loadings*).

- G : un componente inobservable responsable del comportamiento especial atribuible a un factor CV19. Este factor especial sólo actúa durante la submuestra post-CV19, es ortogonal a los factores comunes habituales F y está normalizado a -1 para el mes de abril de 2020, considerado como el de mayor intensidad:
 - $G_t = 0 \quad t = 1..T_0$
 - $\Lambda' \Gamma = 0$
 - $G_t = -1 \quad t = 2020:04$
- Γ : vector $k \times 1$ de cargas del factor CV19. Este vector cuantifica la distinta sensibilidad de cada serie al *shock* CV19.
- U : vector formado por k factores idiosincrásicos, responsables de la dinámica de cada indicador que no es atribuible a los restantes indicadores (vía factores comunes) ni al *shock* CV19.

Estimación

En el MFD hay que estimar: $\Lambda, F_t, U_t, \Gamma$ y G_t . El procedimiento MSW utiliza el siguiente algoritmo:

- a- La matriz de cargas de los factores comunes es estimada mediante componentes principales (PCA), utilizando sólo la submuestra pre-CV19. Estas cargas se mantienen fijas, lo que implica que la dinámica común relevante es la que existía antes del *shock* CV19 y se asume que se mantiene después de éste:

$$\tilde{\Lambda} \leftarrow \text{PCA}(Y_t) \quad t \in [1, T_0]$$

- b- Los factores comunes se estiman, para toda la muestra, mediante MCO sobre las cargas estimadas en el paso anterior:

$$\tilde{F}_t = [\tilde{\Lambda}' \tilde{\Lambda}]^{-1} \tilde{\Lambda}' Y_t \quad t \in [1, T]$$

- c- Los factores idiosincrásicos se estiman, como residuos, para toda la muestra y se selecciona la parte correspondiente a la submuestra post-CV19:

$$\tilde{U}_t = Y_t - \tilde{\Lambda} \tilde{F}_t \quad t \in [T_0 + 1, T]$$

- d- Utilizando sólo la submuestra post-CV19 de dichos factores idiosincrásicos, se estima el factor CV19 a partir de su primer factor común, mediante PCA.

$$\tilde{\Gamma} \leftarrow \text{PCA}(\tilde{U}_t) \quad t \in [T_0 + 1, T]$$

$$\tilde{G}_t = [\tilde{\Gamma}' \tilde{\Gamma}]^{-1} \tilde{\Gamma}' \tilde{U}_t \quad t \in [T_0 + 1, T]$$

- e- El factor CV19 es normalizado para facilitar su interpretación, representando el *shock* CV19 y sus efectos en el tiempo. De esta forma, puede servir como referencia para otros modelos (p.e. como regresor exógeno en el modelo BVAR).

$$G_t = 0 \quad t = 1..T_0$$

$$G_t = -\frac{G_t}{G_{2020:04}} \quad t = 1 \dots T$$

Nótese que el procedimiento seguido asegura $\Lambda'\Gamma = 0$, ya que la forma de estimar los factores comunes (por MCO) y los idiosincrásicos (como residuos), garantiza su ortogonalidad²³. Esta condición es importante para asegurar que el paso (b) funciona adecuadamente, proporcionando una estimación apropiada de F y, por consiguiente, de los elementos de los pasos siguientes: (c), (d) y (e).

A modo de resumen, la siguiente tabla presenta el algoritmo de estimación del procedimiento MSW, diferenciando de nuevo según la submuestra sobre la que se aplica, pre-CV19 o post-CV19.

Tabla A.2
ALGORITMO DE ESTIMACIÓN DEL PROCEDIMIENTO MSW

Parámetros	Submuestra	
	Pre-CV19	Post-CV19
Cargas: Λ		
Factores comunes: F		
Residuos = factor CV19 + factores idiosincrásicos U		
Cargas factor CV19: Γ		
Factor CV19: G		

Aplicación a la economía española

El procedimiento MSW ha sido aplicado a la economía española utilizando como base los indicadores mensuales del MFD utilizado en el Servicio de Estudios Tributarios y Estadísticas de la Agencia Tributaria para el seguimiento en tiempo real del PIB de la economía española (Cuevas *et al.*, 2021).

La aplicación considera dos simplificaciones:

- Como las series son relativamente más cortas, la opción de centrado no utiliza una MM(100) sino directamente el valor medio.
- Los valores atípicos detectados en la submuestra pre-CV19 son reemplazados por su valor medio esperado (cero), en lugar de ser tratados como valores ausentes (*missing*).

²³ Inicialmente, el factor CV19 está mezclado con los residuos extraídos en el paso (c).


La lista de indicadores utilizados es la siguiente:

- Ventas interiores deflactadas (grandes empresas, AEAT).
- Número de perceptores de rendimientos (grandes empresas, AEAT).
- Rendimiento total (grandes empresas, AEAT).
- Consumo de energía eléctrica corregido de efectos de calendario y temperatura (REE).
- Consumo de gasolinas y gasóleo A.
- Exportaciones totales deflactadas (grandes empresas, AEAT).
- Importaciones totales deflactadas (grandes empresas, AEAT).
- Índice de Producción Industrial (IPI).
- Índice de Actividad del Sector Servicios (IASS). Cifra de negocios.
- Consumo aparente de cemento.

La muestra utilizada abarca desde 1996:01 hasta 2022:06. El siguiente gráfico muestra el factor CV19 estimado.

Gráfico A.1

FACTOR CV19 MENSUAL DE LA ECONOMÍA ESPAÑOLA



El factor CV19 concentró su impacto negativo en los meses de marzo y, especialmente, abril de 2020. Los siguientes cinco meses estuvieron marcados por una recuperación de la rápida e intensa caída experimentada en los dos meses anteriores. A partir de octubre de 2020 se aprecian oscilaciones mucho más contenidas que alcanzan valores mínimos a finales de 2021.

El factor CV19 utilizado en el texto principal ha sido integrado, tomando como condición inicial un valor nulo para febrero de 2020 y temporalmente agregado a la frecuencia trimestral. De esta forma, este factor resulta plenamente consistente con la representación en niveles que utiliza el modelo BVAR.

Finalmente, el inicio de una nueva racha de *shocks* asociados a la invasión de Ucrania por parte de Rusia ha aconsejado considerar un valor nulo para el factor CV19 a partir de 2022:1.