



Agosto, 2004

# **BayVAR**

## **Una librería Matlab para el análisis VAR Bayesiano<sup>1</sup>**

Enrique M. Quilis

Instituto Nacional de Estadística

---

<sup>1</sup> El autor agradece los comentarios de Ana Abad, Juan Bógalo, Leandro Navarro y Silvia Relloso. Las opiniones expresadas no reflejan necesariamente las del INE.

## **CONTENIDO**

1. Introducción
  2. Planteamiento teórico
    - 2.1. Restricciones bayesianas. Estimación
    - 2.2. Extensión al caso estacional: el prior de Raynauld-Simonato
    - 2.3. Extensión al caso estacional: el prior de Canova
    - 2.4. Calibrado
  3. Librería de funciones
    - 3.1. Estimación VAR no restringida
    - 3.2. Estimación VAR bayesiana
    - 3.3. Calibrado
    - 3.4. Predicción
    - 3.5. Análisis canónico
    - 3.6. Análisis estructural
- Referencias

## 1. INTRODUCCIÓN

BayVAR es una librería Matlab, diseñada para estimar y analizar modelos Autorregresivos Vectoriales (VAR) desde una perspectiva bayesiana. En particular, surgió para dotar al análisis multivariante de series temporales estacionales de un marco computacional flexible.

El documento posee la siguiente estructura: en la segunda sección se exponen los principales elementos teóricos que conforman el análisis multivariante de series temporales mediante modelos BVAR. A continuación se detallan las funciones Matlab que se han desarrollado para aplicar este enfoque. Se ha centrado la exposición en las funciones esenciales de la librería, si bien existen diversas funciones auxiliares concebidas para imprimir resultados, dibujar gráficos, realizar cálculos específicos o comprobar los resultados, que complementan la librería básica. Los detalles pueden consultarse fácilmente en los textos del comienzo de las funciones, directamente en el código, o a través del comando *help* (i.e. *help var*).

La librería recibe influencias de anteriores trabajos realizados con Ana Abad, Carolina Arias y Rafael Frutos, así como de los requerimientos del Área de Contabilidad Nacional Trimestral (CNTR) del Instituto Nacional de Estadística (INE) orientados a desarrollar herramientas adecuadas para el análisis de la coyuntura y para la compilación de estimaciones rápidas (*flash*) de la CNTR.

BayVAR es una librería econométrica muy específica, por lo que se recomienda su uso combinado con la *Econometrics Toolbox* de James LeSage (1999). Dicha librería se encuentra en la siguiente dirección de Internet: <http://jpl.econ.utoledo.edu/faculty/lesage>.

## 2. PLANTEAMIENTO TEORICO

En esta sección se exponen las principales características de los modelos VAR, con el objeto de centrar el ámbito sobre el que opera BayVAR. Una exposición más detallada se encuentra en Quilis (2002) y en las referencias ahí citadas.

Sea  $Z_t=(z_1, z_2, \dots, z_k)_t'$  un vector de observaciones efectuadas sobre  $k$  variables en el período  $t$ , con  $t=1..n$ . Se considera que  $Z_t$  evoluciona según un modelo vectorial autorregresivo (VAR) de orden  $p$  si puede ser expresado de la siguiente forma:

$$[2.1] \quad Z_t = \mu + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + U_t$$

donde  $\mu$  es un vector de  $k$  constantes y  $\Phi_h$  es una matriz de dimensión  $k \times k$ . El término  $U$  representa una secuencia vectorial de perturbaciones estocásticas de esperanza nula, serialmente incorrelacionadas y con matriz de varianzas y covarianzas constante. Se asume que la función de distribución de probabilidades que genera a  $U_t$  es normal multivariante:

$$[2.2] \quad U_t : k \times 1 \sim N(0, \Sigma)$$

En general, se admite que  $\Sigma$  no es una matriz diagonal, es decir, que existen interacciones contemporáneas entre las  $k$  innovaciones.

Según esta representación, cada variable  $z_{it}$  en un VAR es generada a partir de la suma algebraica de tres elementos:

- valores desfasados de la propia variable (dinámica propia):

$$\sum_{h=1}^p \phi_{h,i,i} Z_{i,t-h}$$

- valores desfasados de las restantes variables (dinámica cruzada):

$$\sum_{\substack{j=1 \\ j \neq i}}^k \sum_{h=1}^p \phi_{h,i,j} Z_{j,t-h}$$

- una innovación específica, posiblemente correlacionada de forma contemporánea con las de las demás variables (innovación):

$$u_{it}$$

Los modelos VAR son estructuras muy generales y, dependiendo de la naturaleza de las matrices  $\Phi_h$  y  $\Sigma$ , aparecen diversos casos particulares.

### 2.1. Restricciones bayesianas. Estimación

Los modelos VAR son representaciones poco parsimoniosas de la estructura dinámica de un vector de series temporales de forma que, incluso en sistemas de dimensión moderada, el número de parámetros que han de ser estimados es muy elevado, agotando eventualmente los grados de libertad de los estimadores. Este hecho, acompañado por la elevada correlación que suelen presentar los regresores de un VAR, da lugar a dos consecuencias funestas: multicolinealidad y sobreajuste.

Con el fin de resolver estos problemas se han propuesto diversas soluciones en línea con los métodos de regresión cresta y de estimación mixta de Theil-Goldberger, véase Judge *et al.* (1980). Así, Litterman (1984a, 1984b, 1986), Doan *et al.* (1984) y Todd (1984, 1988) proponen imponer una serie de restricciones de naturaleza probabilística orientadas a mejorar la calidad de

la estimación y de las predicciones. Estas restricciones, susceptibles de una interpretación bayesiana, no reflejan principios derivados de la teoría económica (usualmente controvertidos) sino consideraciones instrumentales, atóricas, asociadas con nociones de tipo puramente estadístico. Debido a su origen, este tipo de información extramuestral se denomina 'prior de Minnesota' o 'prior de Litterman'.

A continuación se expone dicho prior, para lo que resulta conveniente modificar la notación empleada en [2.1]. La ecuación  $i$ -ésima de un modelo VAR( $p$ ) es:

$$[2.3] \quad Z_i = \begin{pmatrix} i_{n-p} & Z_{i(1)} & \cdots & Z_{i(k(1))} & \cdots & Z_{i(1)(p)} & \cdots & Z_{i(k(p))} \end{pmatrix} \begin{pmatrix} \mu_i \\ \phi_{i,1,1} \\ \vdots \\ \phi_{i,k,1} \\ \vdots \\ \phi_{i,1,p} \\ \vdots \\ \phi_{i,k,p} \end{pmatrix} + U_i = x\beta_i + U_i$$

siendo  $Z_{j(h)}$  el vector de  $(n-p)$  observaciones de la serie  $j$  retardada  $h$  períodos. Nótese que el vector de regresores  $x$  es el mismo en todas las ecuaciones, por lo que la consideración simultánea de las  $k$  ecuaciones que integran el VAR da lugar a la siguiente expresión:

$$[2.4] \quad Z = (I_k \otimes x)\beta + U = X\beta + U$$

siendo  $\otimes$  el producto tensorial de Kronecker y estando  $x$  y  $\beta$  definidos como:

$$x = \begin{pmatrix} i_{n-p} & Z_{i(1)} & \cdots & Z_{i(k(1))} & \cdots & Z_{i(1)(p)} & \cdots & Z_{i(k(p))} \end{pmatrix}$$

y

$$\beta = (\beta_1 \quad \beta_2 \quad \cdots \quad \beta_k)'$$

Naturalmente, el vector  $\beta$  está relacionado con las matrices  $\Phi$  según:

$$[2.5] \quad \beta = \text{vec}(\Phi') \quad \text{con} \quad \Phi = (\mu \quad \Phi_1 \quad \cdots \quad \Phi_p)$$

En consecuencia, la matriz de varianzas y covarianzas de  $U$  es:

$$[2.6] \quad \Sigma_U = \Sigma \otimes I_{n-p} \quad \text{con} \quad \Sigma = \{\sigma_{i,j} \quad i, j = 1..k\}$$

El modelo [2.4] tiene un aspecto similar al del modelo lineal del análisis de regresión, con las debidas consideraciones respecto a la dimensión y estructura de los regresores.

La especificación bayesiana de un modelo VAR considera que los parámetros que forman el vector  $\beta$  son variables aleatorias caracterizadas por una distribución de probabilidad normal multivariante:

$$[2.7] \quad \beta \sim N(\beta^*, V_\beta)$$

En particular, los principios básicos que articulan al prior de Litterman son:

- la dinámica propia es más importante que la cruzada,
- la influencia disminuye a medida que aumenta la distancia temporal,
- las series individuales no son estacionarias y
- no existe cointegración.

La especificación del vector de medias  $\beta^*$  toma como punto de referencia que todas las variables del sistema evolucionan de acuerdo con un paseo aleatorio con deriva:

$$[2.8] \quad (1 - B)z_{i,t} = \mu_i + u_{it} \quad \forall i$$

En consecuencia, se asume que todas las series poseen una tendencia mixta con un componente estocástico asociado a la raíz unitaria en la frecuencia cero (1-B) y con otro determinista, vinculado con el término constante  $\mu_i$ . Obsérvese que, al existir  $k$  raíces unitarias en la representación *a priori* del VAR la posibilidad de cointegración entre la series no es explícitamente considerada. Teniendo en cuenta todos los parámetros involucrados, se tiene:

$$[2.9] \quad \beta^* = \begin{cases} \mu_i = 0 \quad \forall i \\ \phi_{i,j,h} = \begin{cases} 1 & i = j \quad h = 1 \\ 0 & i \neq j \quad h > 1 \end{cases} \end{cases}$$

La matriz de varianzas y covarianzas de  $\beta$  se asume diagonal, y está gobernada por un vector de hiperparámetros  $\pi$  que describe de forma parsimoniosa las propiedades de dicha matriz.

$$[2.10] \quad \text{diagonal}(V_\beta) = \begin{cases} v(\mu_i) = \infty \quad \forall i \\ v(\phi_{i,j,h}) = (\pi_1 F_{i,j} g_h (\sigma_{ii} / \sigma_{jj}))^2 \quad \forall i, j \quad \forall h \end{cases}$$

En primer lugar, se asume un prior difuso para las constantes del modelo, de manera que su estimación estará determinada exclusivamente por la información muestral. En segundo lugar, los restantes parámetros del sistema son considerados como variables aleatorias independientes entre sí (de ahí el carácter diagonal de  $V_\beta$ ) cuyas varianzas están controladas por un reducido vector de hiperparámetros, que actúa sobre tres dimensiones esenciales de un modelo VAR: dinámica propia de primer orden ( $\pi_1$ ), dinámica general ( $g_h$ ) y dinámica cruzada ( $F_{i,j}$ ).

El hiperparámetro  $\pi_1$ , con  $0 \leq \pi_1 < \infty$ , mide el grado de confianza que el analista tiene en el prior sobre la media. Así, si  $\pi_1 \rightarrow 0$  considerará que el parámetro asociado al primer retardo propio es muy próximo a la unidad y, por el contrario, si  $\pi_1 \rightarrow \infty$  adoptará un prior difuso sobre dicho parámetro, dando como resultado que su determinación se haga sólo en función de la información muestral. Asimismo, este hiperparámetro refleja la incertidumbre global que el analista tiene sobre la proximidad del modelo al prior expresado en [2.9], esto es,  $\pi_1$  también cuantifica el grado de incertidumbre global: si  $\pi_1 \rightarrow 0$  el sistema se considera muy similar a  $k$  paseos aleatorios con deriva posiblemente correlacionados de forma contemporánea y, si  $\pi_1 \rightarrow \infty$ , será afín a un modelo VAR no restringido.

La matriz  $F$  específica, desde un punto de vista extramuestral, la interacción dinámica entre las series del modelo. En el caso del prior de Litterman se asume una estructura simétrica de la forma:

$$[2.11] \quad F_{i,j} = \begin{cases} 1 & i = j \\ \pi_2 & i \neq j \end{cases}$$

Así, el hiperparámetro  $\pi_2$ , con  $0 \leq \pi_2 < \infty$ , cuantifica el grado de asociación temporal entre las variables del sistema: si  $\pi_2 \rightarrow 0$  el sistema carecerá de interacción dinámica entre las  $k$  variables que lo integran. Por el contrario, si  $\pi_2 \rightarrow \infty$  no se asumirá hipótesis alguna acerca de estas interacciones, dejando que sea la información muestral la que determine su naturaleza. Naturalmente, este esquema se puede generalizar tanto como se desee de manera que se pueden considerar bloques de variables, asimetrías, etc. Esta generalización implica una menor simplicidad en el modelo al aumentar el número de hiperparámetros.

La función  $g_h$  mide el grado de reducción de la varianza en función del retardo. Puede ser representada utilizando un esquema de decaimiento geométrico o armónico:

$$[2.12] \quad g_h = \begin{cases} h^{-\pi_3} & 0 \leq \pi_3 < \infty \\ \pi_3^{-h} & 0 \leq \pi_3 \leq 1 \end{cases}$$

Adicionalmente, se verifica  $g_h=1$  si  $h=1$ . En ambos casos, a medida que  $h$  aumenta la varianza se aproxima a cero y, por lo tanto, más cerca se encuentra el modelo del prior asociado a  $\beta^*$ . Análogamente, en el caso armónico (geométrico) si  $\pi_3 \rightarrow \infty$  ( $\pi_3 \rightarrow 0$ ) la varianza del parámetro correspondiente se estrecha en torno a cero.

Finalmente, el término  $\sigma_{ii}/\sigma_{jj}$  refleja un factor de escala que hay que tener en cuenta si las variables que forman el modelo están expresadas en distintas unidades de medida. Estas varianzas se pueden determinar bien a través de  $k$  estimaciones AR univariantes o de una estimación VAR no restringida.

En resumen, se tiene un conjunto de restricciones estocásticas que se aplican al vector de coeficientes  $\beta$ , de la forma:

$$[2.13] \quad r = R\beta + w$$

estando  $r$  determinado por  $\beta^*$  -ecuación [2.9]-,  $R$  es una matriz identidad de dimensión  $k(kp+1)$  y  $w$  es una perturbación de media nula y matriz de varianzas y covarianzas determinada por  $V_\beta$  -ecuación [2.10]-. Aplicando el método de estimación mixta de Theil-Goldberger se obtiene el estimador de  $\beta$ :

$$[2.14] \quad \hat{\beta} = ((\Sigma^{-1} \otimes (x'x)) + V_\beta^{-1})^{-1} ((\Sigma^{-1} \otimes x')Z + V_\beta^{-1}\beta^*)$$

La correspondiente matriz de varianzas y covarianzas de  $\hat{\beta}$  es:

$$[2.15] \quad V_{\hat{\beta}} = ((\Sigma^{-1} \otimes (x'x)) + V_\beta^{-1})^{-1}$$

Estas dos ecuaciones describen la distribución *a posteriori* de  $\beta$  en un contexto gaussiano con un prior normal multivariante, de forma que el estimador mixto es una media ponderada del estimador MCO y del prior, dependiendo las ponderaciones de las respectivas matrices de varianzas y covarianzas.

Debe resaltarse que el estimador [2.14] es válido tanto en el caso en que se imponen restricciones simétricas como en el que no lo son. En el primero, siguiendo el álgebra SURE (*Seemingly Unrelated Regression Equations*), equivale a la estimación MCO ecuación por ecuación y, en el segundo, se trata de una estimación sistémica simultánea, véase Judge *et al.* (1980). BayVAR, en sus opciones por defecto, realiza la estimación de modo uniecuacional. No obstante, el código se puede adaptar fácilmente para efectuar estimaciones sistémicas.

## 2.2 Extensión al caso estacional: el prior de Raynauld-Simonato

Resulta posible extender el marco bayesiano expuesto en la subsección anterior para acomodar la presencia del fenómeno estacional. En esta dirección se encuadra la propuesta de Raynauld y Simonato (1993). A continuación se expone el enfoque de estos autores.

Sea  $Z_t$  un vector de observaciones efectuadas sobre  $k$  variables en el período  $t$ , cuya evolución está gobernada por un proceso VAR( $p$ ), siendo  $p$  un múltiplo del número  $s$  de observaciones por período anual:  $p=\tau s$ ,  $\tau \geq 1$ .

$$[2.16] \quad Z_t = \mu + \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + U_t$$

Naturalmente, en el marco estacional  $p$  puede adoptar un valor elevado, con los consiguientes problemas de sobreajuste, multicolinealidad y agotamiento de los grados de libertad ya comentados. En consecuencia, la inclusión de restricciones en [2.16] es prácticamente obligatoria, incluso en sistemas de dimensión reducida,  $k=2$  o  $3$ .

La propuesta de Raynauld y Simonato consiste en generalizar el prior de Litterman de manera que el modelo subyacente sea un paseo aleatorio estacional con deriva:

$$[2.17] \quad (1 - B)(1 - B^s)z_{i,t} = \mu_i + u_{i,t} \quad \forall i$$

En consecuencia, la media del prior sobre los parámetros del modelo VAR( $p$ ) viene dada por:

$$[2.18] \quad \beta^* = \begin{cases} \mu_i = 0 & \forall i \\ \phi_{i,j,h} = \begin{cases} 1 & i = j \quad h = 1, s \\ -1 & i = j \quad h = s + 1 \\ 0 & i \neq j \quad h \neq 1, s, s + 1 \end{cases} \end{cases}$$

La matriz de varianzas y covarianzas del prior también se modifica para tener en cuenta la estructura estacional. Así, estos autores proponen sustituir  $g_h$  por dos nuevas funciones dependientes a su vez de dos hiperparámetros. La primera actúa como un factor que resalta los parámetros estacionales:

$$[2.19] \quad st_h = \begin{cases} h^{-\pi_4} & h = 1..s - 1 \\ (h - (s - 1))^{-\pi_4} & h = s..2s - 1 \\ (h - (2s - 1))^{-\pi_4} & h = 2s..3s - 1 \\ \text{etc.} \end{cases}$$

El hiperparámetro  $\pi_4$  ( $0 \leq \pi_4 < \infty$ ) controla el ritmo de decaimiento fuera de los retardos estacionales, de manera que cuanto mayor es más rápidamente tiende a ceñirse la varianza del parámetro correspondiente hacia cero. Con el fin de limitar la interacción de esta función con el resto de los elementos que definen el prior sobre las varianzas, se introduce la segunda función:



$$[2.20] \quad sd_h = \pi_5^{d_h-1}$$


donde:

$$[2.21] \quad d_h = \begin{cases} 1 & h = 1..s \\ 2 & h = s + 1..2s \\ 3 & h = 2s + 1..3s \\ \text{etc.} \end{cases}$$

El hiperparámetro  $\pi_5$  ( $0 \leq \pi_5 \leq 1$ ) controla el ritmo de decaimiento entre los retardos estacionales, de manera que cuanto menor es más deprisa tiende a ajustarse la varianza del parámetro correspondiente hacia cero. Esta función tiene un aspecto escalonado, manteniendo constante el grado de reducción de la varianza dentro de cada tramo anual.

La interacción entre ambas funciones da como resultado consideraciones extramuestrales muy diferentes con respecto a la pauta estacional de las series del modelo, como se aprecia en el gráfico siguiente:

Gráfico 1: Prior estacional completo, con  $s=12$



Combinando estas dos funciones adicionales con las que ya se consideraron para el caso no estacional, se tiene la siguiente especificación completa de las varianzas del prior sobre los parámetros del modelo:

$$[2.22] \quad \text{diagonal} (V_\beta) = \begin{cases} v(\mu_i) = \infty & \forall i \\ v(\phi_{i,j,h}) = (\pi_1 F_{i,j} st_h sd_h (\sigma_{ii} / \sigma_{jj}))^2 & \forall i, j \quad \forall h \end{cases}$$

donde los restantes elementos tienen el mismo significado que en el caso no estacional. Análogamente, la estimación se realiza de la misma forma que en el caso no estacional mediante el procedimiento de estimación mixta, aplicándose las mismas consideraciones antes expuestas.

## 2.4. Extensión al caso estacional: el prior de Canova

Los modelos VAR pueden ser adaptados al caso estacional mediante la incorporación de información a priori especificada desde el dominio de la frecuencia. A continuación se expone el enfoque propuesto por Canova (1992). Con el fin de facilitar la exposición ésta se centra en el caso univariante.

Los modelos habitualmente considerados para representar el fenómeno estacional implican características especiales en sus representaciones espectrales, véase Maravall (1987). En particular, la más notable es la presencia de picos de potencia (o señal) en las frecuencias asociadas al fenómeno estacional. En este sentido, Canova (1992, 1993) propone incorporar las restricciones que impone la presencia de dichos picos en la representación autorregresiva (AR) de una serie temporal:

$$[2.23] \quad z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + u_t$$

Se asume que el orden del operador AR es mayor o igual que el periodo estacional:  $p \geq s$ . En adelante se supone, sin pérdida de generalidad, que la serie es trimestral:  $s=4$ .

Si el espectro de  $z_t$  posee máximos locales debido a la existencia de raíces unitarias en las frecuencias cero (tendencia),  $\pi/2$  (estacionalidad anual) y  $\pi$  (estacionalidad semestral) entonces los parámetros de [2.23] habrán de verificar ciertas restricciones cuya expresión general es:

$$[2.24] \quad \sum_{h=1}^p \phi_h \cos(hw_c) = 1 \quad w_c = \{0, \pi/2, \pi\}$$

Estas restricciones serán consideradas de forma estocástica debido a tres razones: (i) la selección de un orden finito para el modelo AR implica errores de aproximación, (ii) la información respecto a la frecuencia en la que aparece el pico es inexacta e (iii) el tamaño del pico es desconocido *a priori*.

Formulando [2.24] en notación matricial:

$$[2.25a] \quad R\phi = r + e$$

$$[2.25b] \quad e \sim N(0, Q)$$

Las matrices  $R$  y el vector  $r$  que caracterizan a las restricciones son:

$$R = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & \dots & 1 & 1 & 1 & 1 \\ -1 & 1 & -1 & 1 & -1 & 1 & -1 & 1 & \dots & -1 & 1 & -1 & 1 \\ 0 & -1 & 0 & 1 & 0 & -1 & 0 & 1 & \dots & 0 & -1 & 0 & 1 \end{bmatrix}$$

y

$$r' = [1 \quad 1 \quad 1]$$

La matriz de varianzas y covarianzas del término de error  $e$  es diagonal y su forma es:

$$Q = \Theta \begin{bmatrix} v_1 & 0 & 0 \\ 0 & v_2 & 0 \\ 0 & 0 & v_3 \end{bmatrix}$$

En la expresión anterior  $q$  denota el grado de confianza que el analista aplica a las restricciones, de forma que si tiende a cero (infinito) dichas restricciones son consideradas relevantes (irrelevantes). Los elementos  $v_i$  representan la incertidumbre asociada a la presencia de un pico en la frecuencia  $i$ -ésima. Nuevamente, cuanto menor es su valor mayor es la confianza que el analista tiene en la presencia de un pico en esa frecuencia.

Hasta este momento, el prior de Canova considera que la representación subyacente de la serie  $z_t$  posee un operador autorregresivo de orden  $p$  factorizable según:

$$[2.26] \quad \phi_p(B) = \phi_{p-4}(B)(1-B^4)$$

donde todas las raíces de  $j(B)$  se encuentran fuera del círculo de radio unidad. La estructura de información extramuestral considerada hasta ahora puede ser combinada con la del prior de Litterman, de forma que el modelo subyacente girará en torno al modelo:

$$[2.27] \quad \phi_{p-4}(B)(1-B)(1-B^4)z_t = \mu + u_t$$

La combinación de ambas estructuras de información *a priori* se realiza mediante el método de estimación mixta de Theil-Goldberger:

$$[2.28a] \quad \tilde{\phi} = (V_\phi^{-1} + R'Q^{-1}R)^{-1} (V_\phi^{-1}\phi^* + R'Q^{-1}r)$$

Los elementos  $f$  y  $V_f$  están asociados al prior de Litterman ya expuesto. La correspondiente matriz de varianzas y covarianzas es:

$$[2.28b] \quad \tilde{\Sigma}_\phi = (V_\phi^{-1} + R'Q^{-1}R)^{-1}$$

Finalmente, la información *a priori* y muestral se fusionan según [2.14] y [2.15], considerando el vector de parámetros  $\tilde{\phi}$  y su matriz de varianzas y covarianzas  $\tilde{\Sigma}_\phi$  calculados según [2.28a] y [2.28b] en lugar de  $\beta^*$  y  $\Sigma_{\beta^*}$ .

La extensión de este prior al caso multivariante es conceptualmente sencilla si bien su representación computacional es bastante compleja. Este enfoque asume, esencialmente, un tratamiento idiosincrásico de la estacionalidad. En Canova (1993) se propone un tratamiento más general aunque notablemente más complejo que permite, entre otras cosas, la inclusión de fenómenos como la cointegración estacional detallada por frecuencias.

## 2.4. Calibrado

Antes de realizar la estimación del modelo BVAR, hay que proceder a la determinación del vector de hiperparámetros  $\pi$  en función de algún criterio estadístico relacionado con el uso que se pretenda hacer del modelo. Este proceso se denomina 'calibrado' y es especialmente importante para determinadas aplicaciones de los BVAR como, por ejemplo, el análisis de cointegración (Alvarez y Ballabriga, 1994) o la detección de las estructuras de rango reducido que conducen a los llamados 'modelos índice' o VAR de rango reducido (Reinsel, 1983).

El calibrado puede realizarse mediante consideraciones exclusivamente a priori o bien haciendo uso de la información muestral, basándose en la optimización de una cierta función objetivo  $F(\beta(\pi))$ . Naturalmente, ambas opciones son complementarias, ya que tanto las características estadísticas de los datos como los elementos teóricos pueden condicionar la selección particular de  $\pi$ . El criterio aquí utilizado, que combina los dos enfoques a través de la minimización de los errores de predicción de horizonte uno, se describe con detalle a continuación:

- a) Elección del dominio hiperparamétrico para la optimización. Se ha de elegir un dominio razonable, basado en consideraciones tanto teóricas como empíricas.
- b) Construcción de un mallado, tridimensional -en el caso del prior de Litterman- o tetradimensional -para el de Raynauld y Simonato-, en el dominio hiperparamétrico. Los puntos pertenecientes a dicha retícula serán los candidatos a óptimo.
- c) Diseño de la función objetivo a minimizar,  $F(\beta(\pi))$ , donde  $\pi$  denota al prior. Esta función se evaluará en cada uno de los puntos de la retícula de la siguiente manera: sea  $Z_{(m)}$  la matriz de dimensión  $(n-m) \times k$ :  $Z_{(m)} = \{Z_t : t=1..n-m\}$ , es decir, la matriz que excluye de la muestra las  $m$  últimas observaciones. A continuación, se eliminan de la matriz de observaciones  $Z = \{Z_t : t=1..n\}$  las últimas  $N$  filas, es decir, la muestra queda restringida a  $Z_{(N)}$ . Se estima el modelo BVAR con  $Z_{(N)}$  como muestra y  $\pi$  como vector de hiperparámetros y se calcula, con el modelo estimado,  $\hat{Z}_{(N)}(1)$ , la predicción de horizonte uno para  $Z_{(N)}$ . Puesto que se dispone de la observación muestral  $Z_{n-N+1}$ , se puede calcular el error de predicción  $e_1$ , de dimensión  $k \times 1$ :

$$[2.23] \quad e_1 = Z_{n-N+1} - \hat{Z}_{(N)}(1)$$

- d) De modo iterativo, se estiman modelos BVAR con  $Z_{(N-j)}$ , para  $j=1, \dots, N-1$ , calculando los errores de predicción correspondientes:

$$[2.24] \quad e_{j+1} = Z_{n-(N-j)+1} - \hat{Z}_{(N-j)}(1)$$

Se dispone así de una matriz  $e = (e_1', e_2', \dots, e_N')$  de dimensión  $N \times k$ . Se construye la matriz  $k \times k$  de 'covarianzas no centradas' de  $e$ , esto es,  $E = e'e$ .

- e) De esta manera, solamente resta obtener una medida unidimensional de la magnitud de  $E$ . Las más usuales son: la traza de  $E$ , la media de los  $k$  componentes del estadístico  $U$  de Theil, y, por último, quizá la más utilizada: el log-determinante de la matriz de errores:  $\log(|E|)$ . Posiblemente, esta última es la más completa desde un punto de vista teórico.

- f) Se evalúa la función objetivo en todos los puntos del mallado y se elige como vector de hiperparámetros el que minimiza dicha función.
- g) A veces, resulta conveniente analizar la estabilidad de la optimización, es decir, comprobar si las variaciones del valor de cierto elemento del vector de hiperparámetros, modifican sustancialmente el mínimo en otros elementos. Una forma simple de abordar este problema es tomando los elementos del vector por pares y representando gráficamente la función  $F$  con dos hiperparámetros como ejes y otro de ellos en movimiento (en el caso del prior de Raynauld y Simonato, el hiperparámetro restante, se deja fijado en el óptimo). Así se comprueba si el movimiento producido por uno de los hiperparámetros causa cambios sustanciales en la forma de la superficie representada y, por tanto, si el óptimo se ve seriamente alterado o no por dichas variaciones.

### 3. LIBRERÍA DE FUNCIONES MATLAB

En esta sección se presentan las principales funciones de la librería, utilizando su cabecera (*heading*) como referencia e ilustrando su uso mediante guiones (*script*).

#### 3.1. Estimación var no restringida

Las principales características de la función son:

```
function res = var(Z, p);
% PURPOSE: Unrestricted estimation of a VAR model
% -----
% SYNTAX:  res = var(Z, p)
% -----
% MODEL:  Z(t)=mu+phi(1)*Z(t-1)+...+phi(p)*Z(t-p)+U(t)
%         U(t) : iid(0, sigma)
% -----
% OUTPUT: a structure
%         res.meth      = label
%         res.parm      = number of: observations, effective
%                       observations, series, order of VAR model
%         res.mu        = kx1 intercept
%         res.mu_dt     = kx1 intercept: standard errors
%         res.mu_t      = kx1 intercept: t-ratios
%         res.phi       = kxkxp matrices of parameters PHI(h)
%         res.phi_dt    = PHI(h) parameters: standard errors
%         res.phi_t     = PHI(h) parameters: t-ratios
%         res.U         = (n-p)xk residuals
%         res.sigma     = VCV matrix of residuals
%         res.sigma_corr = correlation matrix of residuals
%         res.perform   = log-likelihood, statistics AIC and BIC
% -----
% INPUT:  Z   = an nxk matrix of original series, columnwise
%         p   = order of the model
% -----
% LIBRARY: lag, vec, desvec, isolator
% -----
% SEE ALSO: var_prt, bvar
```

La estimación de un modelo VAR no restringido puede llevarse a cabo a través del esquema siguiente:

```
Z=load('data.prn');
% Order of VAR model
p=4;
% Estimation of unrestricted VAR model
res = var(Z,p);
% Generating and editing printed results
var_prt(res,'var.sal');
edit var.sal
```

### 3.2. Estimación VAR bayesiana

La estimación de modelos BVAR consta de dos pasos: primero, generación de la estructura del prior que refleja las consideraciones previas del analista acerca de la naturaleza del sistema y, segundo, estimación del modelo a través del método de estimación mixta de Theil-Goldberger. Actualmente, BayVAR incluye dos tipos de priores: Litterman (series temporales no estacionales) y Raynauld-Simonato (series temporales estacionales).

- Generación de priores

El programa dispone de dos funciones para generar el prior: prior\_L (para Litterman) y prior\_RS (para Raynauld-Simonato). La estructura del caso de Litterman es la siguiente:

```
function res = prior_L(k, p, sigma, pi_mu, pi, F, type);
% PURPOSE: Generates a Litterman prior for VAR models
% -----
% SYNTAX: res = prior_L(k, p, sigma, pi_mu, pi, F, type);
% -----
% OUTPUT: res: a structure
%   prior_beta      : prior on the mean, k(kp+1) x 1
%   prior_beta_uni  : idem for uniequational estimation
%   prior_beta_var  : prior on the variance, k(kp+1) x k(kp+1)
%   prior_beta_var_uni : idem for uniequational estimation
%   g               : temporal decay function, px1
% -----
% INPUT:
%   k : # of time series (dimension of the system)
%   p : # of lags
%   sigma : VCV matrix for scaling factors
%   pi_mu : hyperparameter to control de variance of MU
%   pi    : a 1x2 vector of hyperparameters to control the prior
%           variance of PHI
%           pi(1) = global tightness
%           pi(2) = tightness on lag decay
%   F    : kxk matrix with F(i,i)=1 that sets prior on dynamic interactions
%   type : decay function: harmonic (=1) or geometric (=2)
% -----
% LIBRARY: vec
% -----
% SEE ALSO: prior_RS
% -----
% REFERENCE: Litterman, R. B. (1984) "Specifying vector autoregressions
% for macroeconomic forecasting", Federal Reserve Bank of Minneapolis,
% Staff Report n. 92.
```

La estructura del caso de Raynauld-Simonato es:

```

function res = prior_RS(k, p, s, sigma, pi_mu, pi, F, type);
% PURPOSE: Generates a Raynauld-Simonato prior for VAR models
% -----
% SYNTAX: res = prior_RS(k, p, s, sigma, pi_mu, pi, F, type);
% -----
% OUTPUT: res: a structure
%   prior_beta      : prior on the mean, k(kp+1) x 1
%   prior_beta_var  : prior on the variance, k(kp+1) x k(kp+1)
%   g               : temporal decay function, px1
% -----
% INPUT:
%   k : # of time series (dimension of the system)
%   p : # of lags
%   s : # of periods per year (e.g., quarterly: s=4, monthly s=12)
%   sigma : VCV matrix for scaling factors
%   pi_mu : hyperparameter to control de variance of MU
%   pi    : a 1x3 vector of hyperparameters to control the prior
%           variance of PHI
%           pi(1) = global tightness
%           pi(2) = tightness on interseasonal lag decay
%           pi(3) = tightness on seasonal lag decay
%   F    : kxk matrix with F(i,i)=1 that sets prior on dynamic interactions
%   type : centered around (1-B)(1-B^s) (=1) or (1-B^s) (=2)
% -----
% LIBRARY: vec
% -----
% SEE ALSO: prior_L
% -----
% REFERENCE: Raynauld, J. and Simonato, J.G. (1993) "Seasonal BVAR
% models", Journal of Econometrics, vol. 55, p. 203-229.

```

La estructura del prior de Canova es:

```

function res = prior_C(Z, p, s, th_mu, th_L, th_C, v);
% PURPOSE: Generates a Canova prior for multivariate AR models
% -----
% SYNTAX: res = prior_C(Z, p, s, th_mu, th_L, th_C, v);
% -----
% OUTPUT: res: a structure .....
%   prior_beta      : prior on the mean, k(kp+1)x1
%   prior_beta_var  : prior on the variance, k(kp+1)xk(kp+1)
%   rex            : structure linked to prior_L()
% -----
% INPUT:
%   Z : nxk vector of original series, columnwise
%   p : # of lags ==> p >= s
%   s : # of periods per year. Quarterly: s=4, monthly s=12
%   th_mu : 1x1 hyperparameter to control de variance of mu
%   th_L  : 1x3 vector of hyperparameters for Litterman
%   th_C  : 1x1 global uncertainty on Canova prior
%   v    : 1 x km prior variances for inexact restrictions
% -----
% LIBRARY: prior_L
% -----
% SEE ALSO: prior_C_uni, prior_RS
% -----
% REFERENCE: Canova, F. (1992) "An alternative approach to modeling
% and forecasting seasonal time series", Journal of Business and
% Economic Statistics, vol. 10, n. 1, p. 97-108.
% -----

```



- Estimación mixta Theil-Goldberger

La función *bvar* lleva a cabo la estimación, teniendo en cuenta la estructura del prior diseñada por el usuario.

```

function res = bvar(Z, p, prior, sigma_ini);
% PURPOSE: Estimation of a BVAR model
% -----
% SYNTAX:  res = res = bvar(Z, p, prior, sigma_ini);
% -----
% OUTPUT: a structure
%         res.meth      = label
%         res.parm      = number of: observations, effective
%                       observations, series, order of VAR model
%         res.mu        = kx1 intercept
%         res.mu_dt     = kx1 intercept: standard errors
%         res.mu_t      = kx1 intercept: t-ratios
%         res.phi       = kxkxp matrices of parameters PHI (h)
%         res.phi_dt    = PHI (h) parameters: standard errors
%         res.phi_t     = PHI (h) parameters: t-ratios
%         res.U         = (n-p)xk residuals
%         res.sigma     = VCV matrix of residuals
%         res.sigma_corr = correlation matrix of residuals
%         res.perform   = log-likelihood, statistics AIC and BIC
% -----
% INPUT: Z             = an nxk matrix of original series, columnwise
%         p             = the maximum lag, p>=1
%         prior: a structure with ...
%         prior.prior_beta = prior on the mean, k(kp+1) x 1
%         prior.prior_beta_var = prior on the variance,
%                               k(kp+1) x k(kp+1)
%         sigma_ini     = initial VCV matrix of residuals, kxk
% -----
% LIBRARY: lag, vec, desvec, isolator
% -----
% SEE ALSO: var

```

Nuestra estimación de un modelo BVAR responde al siguiente esquema:

```

Z=load('data.prn');
% Order of VAR model
p=13;
% Seasonal frequency
s=12;
% -----
% Prior generation
% -----
% Initial estimation of sigma by means of univariate AR
sigma=sigma_AR(Z,p);
% Setting dynamic interactions
F=ones(k,k); F(1,2)=0.4; F(2,1)=0.4;
% Setting prior variance of intercept
pi_mu=10000;
% Setting decay hyperparameters
pi=[0.2 0.5 1.0];
type=1;
% Final generation of prior

```

```
prior = prior_RS(k,p,s,sigma,pi_mu,pi,F,type);
prior_RS_prt(prior,k,p,s,pi_mu,pi,F,type,'prior.sal',0);
edit prior.sal
% Estimation of BVAR model
res=bvar(Z,p,prior,sigma);
var_prt(res,'bvar.sal');
edit bvar.sal
% Generating and editing printed results
var_prt(res,'var.sal');
edit var.sal
```

### 3.3. Calibrado

La determinación de los hiperparámetros más adecuados es un elemento clave en el proceso de modelización BVAR. No hay modos simples de acometer esta tarea y con cualquier método surgen problemas y dificultades. De todos modos, se han incluido dos funciones con el fin de ayudar al analista a elegir la estructura hiperparamétrica. La primera evalúa la capacidad predictiva del modelo y la segunda realiza una búsqueda exhaustiva en rejilla dentro del espacio hiperparamétrico que se considere admisible. En esta búsqueda es posible elegir direcciones específicas, un rango concreto o diversos refinamientos de la malla.

```
function res = err(Z, p, N, pi_mu, pi, F, type, s);
% PURPOSE: Computes one-step ahead forecasting errors and two measures of its
size
% -----
% SYNTAX: res = err(Z, p, N, pi_mu, pi, F, type, s);
% -----
% OUTPUT: a structure:
%         res.e      : Nxk matrix of errors (e)
%         res.crit1  : trace(e'e)
%         res.crit2  : log(det(e'e))
%         res.crit3  : Theil's U
% -----
% INPUT: Z      = an nxk matrix of original series, columnwise
%         p      = the maximum lag, p>=1
%         N      = number of final data to evaluate errors
% Optional:
%         * If seven (7) inputs are included, it is assumed that a BVAR
%         with Litterman priors is being used (non-seasonal BVAR):
%         pi_mu : hyperparameter to control de variance of MU
%         pi    : a 1x2 vector of hyperparameters to control the prior variance of
%         PHI
%         type  : decay function: harmonic (=1) or geometric (=2)
%         * If eight (8) inputs are included, it is assumed that a BVAR
%         with Raynauld-Simonato priors is being used (seasonal BVAR):
%         pi_mu : hyperparameter to control de variance of MU
%         pi    : a 1x3 vector of hyperparameters to control the prior variance of
%         PHI
%         type  : centered around (1-B)(1-B^s) (=1) or (1-B^s) (=0)
%         s    : # of periods per year (e.g., quarterly: s=4, monthly s=12)
% -----
% LIBRARY: var, bvar, predict, sigma_AR, prior_L, prior_RS
% -----
% SEE ALSO:
% -----
% REFERENCE: Doan, Th., Litterman, R. B. and Sims, Ch. A. (1984) "Forecasting
% and conditional projection using realistic prior distributions", Econometric
% Review, n. 3, p. 1-100.
```

La búsqueda en rejilla se computa con la función<sup>2</sup>:

```

function opt=calibra(Z, p, N, pi_mu, type, s)
% PURPOSE: Minimize the log-determinant of the matrix of summed cross-products
% of one-step-ahead out-of-sample forecast errors of the estimation of a BVAR
% model using the Litterman or the Raynaud-Simonato prior.
% See err for details about the function to minimize.
%-----
% SYNTAX:  opt=calibra(Z, p, N, pi_mu, type, s)
%-----
% OUTPUT: opt: a structure...
%         for the three criteria (i=1, 2, 3):
%             opt.pi_opti=pi_min_i --> hyperparameters at minimum
%             opt.pi_Fopti=pi_Fmin(i) --> F-hyperparameter at minimum
%
%             Next three cells are the values of objective function
%             (criteria i) at minimum following the other criteria.
%
%             The rest of the structure was designed to be used with
%             the graphics program calibra_plt.
%-----
% INPUT:
%         Z: a nxk matrix of original series, columnwise
%         p: order of the model
%         s: number of periods per year (e.g., quarterly: s=4, monthly s=12)
%         N: number of periods to one-step-ahead forecast (the N last
%             periods of the sample)
%         pi_mu: hyperparameter to control de variance of MU
%         type: centered around (1-B)(1-B^s) (=1) or (1-B^s) (=0) (RS)
%              decay function: harmonic (=1) or geometric (=2) (L)
%         s (optional) seasonal frequency
%-----
% LIBRARY:  err, gF
%-----
% SEE ALSO: calibra_plt, var, bvar, prior_L, prior_RS
%-----
% REFERENCE: Doan, Th., Litterman, R. B. and Sims, Ch. A. (1984) "Forecasting
% and conditional projection using realistic prior distributions", Econometric
% Review, n. 3, p. 1-100.

```

El calibrado de un modelo BVAR responde al esquema que sigue:

```

Z=load('data.prn');
% Order of VAR model
p=13;
% Seasonal frequency
s=12;
% Number of periods to one-step-ahead forecast
N=17;
% Setting prior variance of intercept
pi_mu=10000;
% Setting decay hyperparameters (L)
% or setting center of random walk (R-S)
type=1;
% Calibration of BVAR model
opt=calibra(Z,p,N,pi_mu,type,s);
% Setting criteria of minimizing to plot results

```

<sup>2</sup> Esta función ha sido desarrollada por Jesús Bouso.

```

criteria=2;
% Setting kind of graphic to plot results
% graphic=1;
% Generating plotted results
mov=calibra_plt(opt,criteria,graphic);

```

### 3.4. Predicción

Una de las principales aplicaciones de los modelos VAR es la predicción. BayVAR incluye la siguiente función que genera predicciones incondicionales y sus correspondientes desviaciones típicas:

```

function rex = predict(Z, res, npred);
% PURPOSE: Prediction from a VAR model
% -----
% SYNTAX:  rex = predict(Z, res, npred);
% -----
% OUTPUT:  rex: a structure
%          rex.Zf   = npred x k matrix of forecasts (columnwise)
%          rex.sff  = npred x k matrix of std of forecasts (columnwise)
% -----
% INPUT:   Z       = an nxk matrix of original series, columnwise
%          res     = structure from function var or bvar
%          npred   = number of forecasts
% -----
% LIBRARY: lag, irf
% -----
% SEE ALSO: var, bvar

```

La predicción con modelos BVAR se realiza mediante el siguiente esquema:

```

Z=load('data.prn');
% Order of VAR model
p=4;
% Estimation of unrestricted VAR model
res = var(Z,p);
% Forecasting
npred=6;
resf = predict(Z,res,npred);
% Joining forecasts (including sigma-limits) and data
ZZ=[Z
    resf.Zf];
ZZ_ls=[Z
    resf.Zf+resf.sff];
ZZ_li=[Z
    resf.Zf-resf.sff];
% Plot
t=100:size(ZZ,1);
plot(t,ZZ_li(100:end,1),'-r',t,ZZ_ls(100:end,1),'-r',t,ZZ(100:end,1),'-b');
legend('Upper lim.','Lower lim.','Predicted',0);

```

### 3.5. Análisis canónico

La metodología propuesta por Box y Tiao (1977) es un modo simple, efectivo y relativamente robusto para explorar la estructura subyacente a un vector de series temporales y estudiar la existencia de cointegración. Se ha incluido una función para llevar a cabo dicho análisis. Esta función también aporta información adicional concerniente a los autovalores del sistema.

```
function res_can = canonical(Z, res);
% PURPOSE: Eigen analysis of a VAR model
% -----
% SYNTAX:  res_can = canonical(Z, res);
% -----
% OUTPUT: a structure
% res_can.meth      = label
% res_can.lambda    = kx1 vector of BT eigenvalues
% res_can.M         = kxk matrix of Box-Tiao eigenvectors (columnwise)
% res_can.can       = can nxk: canonical variates
% res_can.lambda_sigma = kx1 vector of eigenvalues of residual VCV
% res_can.M_sigma   = kxk matrix of eigenvectors (columnwise) of
%                   residual VCV
% res_can.lambdaH   = lambdaH eigenvalues of PHI companion matrix of VAR
% -----
% INPUT: Z          = an nxk matrix of original series, columnwise
%       res         = structure generated by var.m or bvar.m
% -----
% LIBRARY:
% -----
% SEE ALSO: canonical_prt, canonical_plt, irf, var, bvar
% -----
% Reference: Box, G. E. P. and Tiao G. C. (1977), "A canonical analysis
% of multiple time series". Biometrika, Number 64, pp. 355-365.
```

El análisis canónico con modelos VAR responde al esquema que sigue:

```
Z=load('data.prn');
% Order of VAR model
p=4;
% Estimation of unrestricted VAR model
res = var(Z,p);
% Canonical analysis
res_can = canonical(Z,res);
% Printed output
canonical_prt(res,res_can,'can.sal');
edit can.sal
% Graphical output
canonical_plt(Z,res_can);
```

### 3.6. Análisis estructural

Desde el trabajo pionero de Sims (1980), los modelos VAR son una herramienta habitual tanto para el análisis como para la evaluación de políticas macroeconómicas, a través de la modelización VAR estructural (SVAR).

La librería dispone de tres funciones de análisis estructural que calculan: i) la función impulso-respuesta, ii) los intervalos de confianza para funciones de impulso-respuesta basados en una formulación analítica e iii) la descomposición de la varianza del error de predicción para diferentes horizontes.

```
function rex = irf(res, sigma, T, type);
% PURPOSE: Compute the impulse-response function of a VAR
% -----
% SYNTAX:  rex = irf(res, sigma, T, type);
% -----
% OUTPUT:  rex : a structure ....
%          FF: a cube containing the irf: response of i variable
%          to a shock in j measured in time h
%          Uo : structural (orthogonalized) residuals
%          type : orthogonalization (see below)
%          Shocks : matrix of shocks (irf at lag 0)
%          H: pkxpk companion matrix in stacked VAR(1) state-space form
%          (dynamics)
%          G: kxpk selection matrix of state-space form measurement eq.
% -----
% INPUT:
%       res = a structure, output of VAR.m or BVAR.m
%       sigma = VCV of structural shocks (may be eye(k) if Cholesky is
%       requested)
%       T = number of periods to compute irf
%       type = 0 (compute Cholesky), 1 (do not compute Cholesky)
%       if type=0 VCV of VAR is orthogonalized, if =1 no Cholesky is applied
% -----
% NOTE:
%       PHI-weights of the VAR model may be computed setting sigma=eye(k)
%       and type=1
% -----
% LIBRARY:
% -----
% SEE ALSO: irf_prlt, var, bvar
```

Los intervalos de confianza para las funciones de impulso-respuesta pueden ser generados usando de la siguiente función<sup>3</sup>:

```

function fri=irfse(res, T, sigma);
% PURPOSE: Compute the impulse-response function of a VAR with their
%          standard error bounds
% -----
% SYNTAX:  fri=irfse(res, T, sigma);
% -----
% OUTPUT:  fri : a structure ...
%          fri.phi, fri.theta, fri.sctheta: cubes containing the irf:
%          response of i variable to a shock in j measured in time h [irf,
%          orthogonalized irf and re-scaled orthogonalized irf, respectively]
%
%          fri.sdphi, fri.sdtheta, fri.scsdtheta: standard errors of previous
%          variables
% -----
% INPUT:
%          res = a structure, output of VAR.m or BVAR.m
%          T = number of periods to compute irf
%          (optional) sigma = VCV of structural shocks ( default, sigma=eye(k))
% -----
% NOTE:
%          PHI-weights of the VAR model may be computed setting sigma=eye(k)
%          and type=1
% -----
% LIBRARY: irf, scala, desvec, elimina, commuta, duplica, conversion
% -----
% SEE ALSO: irfse_plt, irf_prlt, var, bvar
% -----
% REFERENCE: Helmut Lutkepohl, "Introduction to Multiple Time Series Analysis"
% Second Edition. Springer-Verlag Berlin-Heidelberg 1991, 1993
% Chapters 2, 3.

```

La descomposición de la varianza del error de predicción se genera a través de la función que sigue<sup>4</sup>:

```

function fevd=fevd(res, nh);
% PURPOSE: Compute the Forecast Error Variance Decomposition
%          of a VAR model
% -----
% SYNTAX:  fevd=fevd(res, nh)
% -----
% OUTPUT:  fevd: a (nh x k x k) matrix with the variance
%          decomposition. The cell (h,j,i) contain the proportion
%          of fev of variable i, h periods ahead, accounted for
%          by innovations in the variable j
% -----
% INPUT:   res : a structure, output of var.m or bvar.m
%          nh: maximum forecast horizon
% -----
% LIBRARY: irf
% -----
% SEE ALSO: irfse

```

<sup>3</sup> Esta función ha sido desarrollada por Jesús Bouso.

<sup>4</sup> Esta función ha sido desarrollada por Jesús Bouso.



## REFERENCIAS

- Alvarez, L.J. y Ballabriga, F.C. (1994) "BVAR models in the context of cointegration: a Monte Carlo experiment", Banco de España, Documento de Trabajo n. 9405.
- Box, G.E.P. y Tiao, G.C. (1977) "A canonical analysis of multiple time series", *Biometrika*, vol. 64, n. 2, p. 355-365.
- Canova, F. (1992) "An alternative approach to modeling and forecasting seasonal time series", *Journal of Business and Economic Statistics*, vol. 10, n. 1, p. 97-108.
- Canova, F. (1993) "Forecasting time series with common seasonal patterns", *Journal of Econometrics*, vol. 55, n. 1. p. 73-200.
- Doan, Th., Litterman, R.B. y Sims, Ch.A. (1984) "Forecasting and conditional projection using realistic prior distributions", *Econometric Review*, n. 3, p. 1-144.
- Judge, G.C., Griffiths, W.E., Carter Hill, R. y Lee, T.C. (1980) *The theory and practice of econometrics*, John Wiley and Sons, New York, Estados Unidos de América.
- LeSage, J.P. (1999) "Applied econometrics using MATLAB", University of Toledo (Ohio), Department of Economics, Documento Interno.
- Litterman, R.B. (1984a) "Specifying vector autoregressions for macroeconomic forecasting", Federal Reserve Bank of Minneapolis, Staff Report n. 92.
- Litterman, R.B. (1984b) "Forecasting and policy analysis with bayesian vector autoregression models", Federal Reserve Bank of Minneapolis, *Quarterly Review*, vol. 8, n. 4, p. 30-41.
- Litterman, R.B. (1986) "Forecasting with bayesian vector autoregressions - five years of experience", *Journal of Business and Economic Statistics*, vol. 4, n. 1, p. 25-38.
- Maravall, A. (1987) "Descomposición de series temporales. Especificación, estimación e inferencia", *Estadística Española*, vol. 29, n. 114, p. 11-69.
- Quilis, E.M. (2002) "Modelos BVAR: especificación, estimación e inferencia", Instituto de Estudios Fiscales, Papeles de Trabajo n. 8/02.
- Raynauld, J. y Simonato, J.G. (1993) "Seasonal BVAR models", *Journal of Econometrics*, vol. 55, p. 203-229.
- Reinsel, G.C. (1983) "Some results on multivariate autoregressive index models", *Biometrika*, vol. 70, n. 1, p. 145-156.
- Sims, Ch.A. (1980) "Macroeconomics and reality", *Econometrica*, vol. 48, n. 1, p. 1-48.
- Todd, R.M. (1984) "Improving economic forecasting with bayesian vector autoregressions", Federal Reserve Bank of Minneapolis, *Quarterly Review*, vol. 8, n. 4, p. 18-29.
- Todd, R.M. (1988) "Implementing bayesian vector autoregressions", Federal Reserve Bank of Minneapolis, Working Paper n. 384.