

Vectores Autoregresivos desde una Perspectiva Bayesiana

Macroeconometría Aplicada

Juan Guerra-Salas

Pontificia Universidad Católica de Chile
Segundo Semestre 2020

- ▶ Sacaré contenido de **Blake y Mumtaz (2017)**, **cáp. 2**.
- ▶ Las técnicas Bayesianas que discutimos en el contexto de una regresión lineal pueden extenderse para modelos VAR.
- ▶ Los modelos VAR Bayesianos combinan información externa (*priors*) con la información contenida en los datos (*likelihood*), para obtener la distribución posterior de los parámetros.
- ▶ Las técnicas de muestreo que se usan en estimación Bayesiana permiten caracterizar fácilmente la incertidumbre alrededor de objetos como funciones impulso-respuesta.

- 1 El VAR a estimar.
- 2 *Priors* y *posteriors* condicionales de parámetros y matriz de varianza-covarianza: descripción general.
- 3 Algoritmo de muestreo de Gibbs.
- 4 Formulación de *priors*: descripción específica. El *Minnesota prior*.
- 5 Aplicación 1: *Shocks* monetarios en Chile. Identificación por estructura recursiva.
- 6 Aplicación 2: *Shocks* monetarios en Chile. Identificación por restricciones de signo.

- ▶ Consideren el siguiente VAR(p):

$$Y_t = c + Y_{t-1}B_1 + Y_{t-2}B_2 + \dots + Y_{t-p}B_p + v_t,$$
$$E(v_t'v_s) = \Sigma \quad \text{si } t = s,$$
$$E(v_t'v_s) = 0 \quad \text{si } t \neq s,$$
$$E(v_t) = 0.$$

- ▶ Y_t es un vector ($1 \times N$) de variables endógenas, c es un vector ($1 \times N$) de constantes, B_i son matrices ($N \times N$) de coeficientes, y v_t es un vector de errores. Cada columna representa una ecuación del sistema.
- ▶ El VAR se puede escribir de manera más compacta:

$$Y_t = X_t B + v_t,$$

donde $X_t = [1 \ Y_{t-1} \ Y_{t-2} \ \dots \ Y_{t-p}]$ es un vector de dimensión $[1 \times (N * P + 1)]$ y B es una matriz de dimensión $[(N * P + 1) \times N]$.

Ejemplo de la notación (1/2)

- Consideren un VAR bivariado con dos rezagos para la inflación π_t y la tasa de política monetaria R_t .

$$\begin{aligned}\pi_t &= c_\pi + b_{11}\pi_{t-1} + b_{12}R_{t-1} + d_{11}\pi_{t-2} + d_{12}R_{t-2} + v_{\pi t}, \\ R_t &= c_R + b_{21}\pi_{t-1} + b_{22}R_{t-1} + d_{21}\pi_{t-2} + d_{22}R_{t-2} + v_{Rt}.\end{aligned}$$

- En términos de vectores y matrices, donde cada **columna** representa una ecuación, el sistema puede escribirse así:

$$\begin{aligned}[\pi_t \quad R_t] &= [c_\pi \quad c_R] + [\pi_{t-1} \quad R_{t-1}] \begin{bmatrix} b_{11} & b_{21} \\ b_{12} & b_{22} \end{bmatrix} \\ &\quad + [\pi_{t-2} \quad R_{t-2}] \begin{bmatrix} d_{11} & d_{21} \\ d_{12} & d_{22} \end{bmatrix} + [v_{\pi t} \quad v_{Rt}].\end{aligned}$$

Ejemplo de la notación (2/2)

- De manera más compacta, el sistema puede escribirse así:

$$\underbrace{\begin{bmatrix} \pi_t & R_t \end{bmatrix}}_{Y_t} = \underbrace{\begin{bmatrix} 1 & \pi_{t-1} & R_{t-1} & \pi_{t-2} & R_{t-2} \end{bmatrix}}_{X_t} \underbrace{\begin{bmatrix} c_\pi & c_R \\ b_{11} & b_{21} \\ b_{12} & b_{22} \\ d_{11} & d_{21} \\ d_{12} & d_{22} \end{bmatrix}}_B + \underbrace{\begin{bmatrix} v_{\pi t} & v_{Rt} \end{bmatrix}}_{v_t},$$

$$Y_t = X_t B + v_t.$$

Volviendo a nuestro VAR genérico...

$$Y_t = c + Y_{t-1}B_1 + Y_{t-2}B_2 + \dots + Y_{t-p}B_p + v_t,$$

$$Y_t = X_t B + v_t.$$

- ▶ También puede escribirse así:

$$y_t = (I_N \otimes X_t)b + V_t.$$

- ▶ I_N es una matriz identidad de dimensión $(N \times N)$.
- ▶ $y = \text{vec}(Y_t)$, $b = \text{vec}(B)$, $V = \text{vec}(v_t)$.
- ▶ vec es un operador que “vectoriza” una matriz, poniendo cada columna debajo de la anterior.
- ▶ \otimes es el producto de Kronecker: $I_N \otimes X$ indica que cada elemento de I_N se multiplica por toda la matriz X .
- ▶ Demostración en [apéndice A](#).

Prior y posterior de los parámetros del VAR (1/3)

- ▶ Nuestro objetivo es estimar los coeficientes b y la matriz de varianza-covarianza Σ .
- ▶ El *prior* conjugado para los coeficientes b es normal:

$$P(b) \sim N(\tilde{b}_0, H).$$

- ▶ \tilde{b}_0 es la media del *prior*; un vector $[N \times (N \times P + 1)] \times 1$.
- ▶ H es una matriz cuyos elementos de la diagonal principal son la varianza del *prior*; H tiene dimensión $[N \times (N \times P + 1)] \times [N \times (N \times P + 1)]$.
- ▶ Como para una regresión lineal (tema anterior del curso), se usa distribución posterior de b condicional en Σ para aproximar distribución posterior marginal de b .

Prior y posterior de los parámetros del VAR (2/3)

- ▶ La distribución posterior de b condicional en Σ también es normal:

$$H(b|\Sigma, Y_t) \sim N(M^*, V^*),$$

$$M^* = (H^{-1} + \Sigma^{-1} \otimes X_t'X_t)^{-1} \left(H^{-1}\tilde{b}_0 + \Sigma^{-1} \otimes X_t'X_t\hat{b} \right),$$

$$V^* = (H^{-1} + \Sigma^{-1} \otimes X_t'X_t)^{-1}.$$

- ▶ \hat{b} contiene los estimadores OLS de los parámetros del VAR.
- ▶ La media de la *posterior* es un promedio ponderado de la media del *prior* \tilde{b}_0 y del estimador OLS \hat{b} .
- ▶ Noten el rol de la varianza del *prior*. Mientras más grande sea, menor será la importancia del *prior*.

Prior y posterior de los parámetros del VAR (3/3)

- ▶ El *prior* conjugado de la matriz de varianza-covarianza de los residuos tiene una distribución *inverse Wishart* con matriz de escala \bar{S} y grados de libertad α :

$$P(\Sigma) = IW(\bar{S}, \alpha).$$

- ▶ La distribución *inverse Wishart* es un análogo multivariado de la distribución *inverse Gamma*.
- ▶ La *posterior* de Σ condicional en b también es *inverse Wishart*:

$$H(\Sigma|b, Y_t) \sim IW(\bar{\Sigma}, T + \alpha).$$

- ▶ $\bar{\Sigma}$ es la matriz de escala de la *posterior* condicional; $T + \alpha$ son los grados de libertad. T es el número de observaciones.

$$\bar{\Sigma} = \bar{S} + (Y_t - X_t B)'(Y_t - X_t B).$$

- ▶ Recuerden que B son los coeficientes del VAR en forma de una matriz de dimensión $(N \times P + 1) \times N$.

El algoritmo de muestreo de Gibbs para un VAR

- 1 Formular *priors* para los coeficientes y la matriz de varianza-covarianza de los residuos: $P(b) \sim N(\tilde{b}_0, H)$, $P(\Sigma) \sim IW(\bar{S}, \alpha)$. Definir un valor inicial para Σ .
- 2 Tomar una muestra de la distribución posterior condicional de los coeficientes $H(b|\Sigma, Y_t) \sim N(M^*, V^*)$. Con M^* y V^* se obtiene una muestra de la distribución normal:

$$b^1 = M^* + [\bar{b} \times (V^*)^{1/2}],$$

donde \bar{b} es una muestra de la distribución multivariada normal estándar.

- 3 Tomar una muestra de la dist. posterior condicional de Σ , $H(\Sigma|b, Y_t) \sim IW(\bar{S}, T + \alpha)$, usando la muestra previa de parámetros b^1 como insumo. Se obtiene Σ^1 .
- 4 Repetir los dos pasos anteriores M veces, lo que ofrece B^1, \dots, B^M y $\Sigma^1, \dots, \Sigma^M$. Se usan los últimos H valores de B y Σ para formar la distribución empírica de los parámetros, y para calcular otros objetos como pronósticos y funciones impulso-respuesta.

Formulación de *priors* (1/6)

- ▶ Aquí revisamos exactamente cómo se definen los *priors*.
- ▶ Volvamos a nuestro ejemplo de dos variables y dos rezagos:

$$\begin{aligned} [\pi_t \quad R_t] &= [c_\pi \quad c_R] + [\pi_{t-1} \quad R_{t-1}] \begin{bmatrix} b_{11} & b_{21} \\ b_{12} & b_{22} \end{bmatrix} \\ &\quad + [\pi_{t-2} \quad R_{t-2}] \begin{bmatrix} d_{11} & d_{21} \\ d_{12} & d_{22} \end{bmatrix} + [v_{\pi t} \quad v_{Rt}]. \end{aligned}$$

- ▶ El *Minnesota prior* consiste en que las variables del sistema siguen un proceso AR(1) o de caminata aleatoria. Bajo la media de este *prior*, el sistema toma la siguiente forma:

$$\begin{aligned} [\pi_t \quad R_t] &= [0 \quad 0] + [\pi_{t-1} \quad R_{t-1}] \begin{bmatrix} b_{11}^0 & 0 \\ 0 & b_{22}^0 \end{bmatrix} \\ &\quad + [\pi_{t-2} \quad R_{t-2}] \begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix} + [v_{\pi t} \quad v_{Rt}]. \end{aligned}$$

- ▶ b_{11}^0 y b_{22}^0 son los *priors* AR(1) si son menores que 1, o de caminata aleatoria si son iguales a 1.

Formulación de *priors* (2/6)

- ▶ Por tanto, la media del prior de los parámetros $P(b) \sim N(\tilde{b}_0, H)$ toma la siguiente forma:

$$\tilde{b}_0 = \begin{bmatrix} 0 \\ b_{11}^0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ b_{22}^0 \\ 0 \\ 0 \end{bmatrix} .$$

- ▶ Las primeras 5 filas de este vector corresponden a los parámetros de la primera ecuación y las últimas 5 filas a los de la segunda ecuación.

Formulación de *priors* (3/6)

- ▶ La varianza de este prior H toma la siguiente forma (intuición más adelante):

$$H_{(10 \times 10)} = \begin{bmatrix} H_1 & 0_{(5 \times 5)} \\ 0_{(5 \times 5)} & H_2 \end{bmatrix},$$
$$H_1 = \begin{bmatrix} (\sigma_1 \lambda_4)^2 & 0 & 0 & 0 & 0 \\ 0 & (\lambda_1)^2 & 0 & 0 & 0 \\ 0 & 0 & \left(\frac{\sigma_1 \lambda_1 \lambda_2}{\sigma_2}\right)^2 & 0 & 0 \\ 0 & 0 & 0 & \left(\frac{\lambda_1}{2^{\lambda_3}}\right)^2 & 0 \\ 0 & 0 & 0 & 0 & \left(\frac{\sigma_1 \lambda_1 \lambda_2}{\sigma_2 2^{\lambda_3}}\right)^2 \end{bmatrix},$$

Formulación de *priors* (4/6)

$$H_2 = \begin{bmatrix} (\sigma_2 \lambda_4)^2 & 0 & 0 & 0 & 0 \\ 0 & \left(\frac{\sigma_2 \lambda_1 \lambda_2}{\sigma_1}\right)^2 & 0 & 0 & 0 \\ 0 & 0 & (\lambda_1)^2 & 0 & 0 \\ 0 & 0 & 0 & \left(\frac{\sigma_2 \lambda_1 \lambda_2}{\sigma_1 2^{\lambda_3}}\right)^2 & 0 \\ 0 & 0 & 0 & 0 & \left(\frac{\lambda_1}{2^{\lambda_3}}\right)^2 \end{bmatrix} .$$

- ▶ σ_1, σ_2 son desvíos estándar de términos de error estimados por regresiones AR(1) (estimadas por OLS) para las variables 1 y 2. Se necesitan por si las variables tienen diferentes escalas.

Formulación de *priors* (5/6)

- ▶ Los parámetros λ_1 , λ_2 , λ_3 , λ_4 controlan la estrechez del *prior*, y se determinan, para cada coeficiente b_{ij} , así:

$$\begin{aligned} & \left(\frac{\lambda_1}{l\lambda_3} \right)^2 & \text{si } i = j \\ & \left(\frac{\sigma_i \lambda_1 \lambda_2}{\sigma_j l \lambda_3} \right)^2 & \text{si } i \neq j \end{aligned}$$

$(\sigma_i \lambda_4)^2$ para la constante.

- ▶ i se refiere a la variable dependiente de la ecuación i -ésima; j a la variable independiente de esa ecuación. Cuando $i = j$, se trata de coeficientes sobre rezagos de la misma variable i . l se refiere al número de rezago asociado al coeficiente b_{ij} .

Formulación de *priors* (6/6)


- ▶ λ_1 controla el desvío estándar del *prior* sobre los propios rezagos de cada variable. Cuando $\lambda_1 \rightarrow 0$, $b_{11}, b_{22} \rightarrow b_{11}^0, b_{22}^0$ y los parámetros asociados a otros rezagos $\rightarrow 0$.
- ▶ λ_2 controla el desvío estándar del *prior* sobre variables que no son la dependiente (b_{12}, b_{21} , etc.) $\lambda_2 \rightarrow 0$, $b_{ij}, d_{ij} \rightarrow 0$. Cuando $\lambda_2 = 1$, rezagos de variables que no son la dependiente en efecto se tratan igual que rezagos de la variable dependiente.
- ▶ λ_3 controla la medida en que coeficientes de rezagos mayores que 1 son 0. Mientras mayor es λ_3 , más probable que estos coeficientes tomarán valores de 0. Noten que l describe el rezago al que se asocia cada coeficiente.
- ▶ λ_4 controla la varianza del *prior* sobre la constante. Cuando $\lambda_4 \rightarrow 0$, las constantes $\rightarrow 0$.

Aplicación 1: *Shocks* monetarios en Chile; identificación recursiva (1/4)

- ▶ En esta aplicación usamos datos sobre inflación, brecha del producto y tasa de política monetaria (TPM) para estimar el efecto de un *shock* a la TPM.
- ▶ La muestra cubre el periodo 2001:T3–2019:T3.
- ▶ Para identificar *shocks* estructurales, suponemos una estructura recursiva, según la cual: (i) la TPM responde de manera contemporánea a la inflación y la brecha del producto, (ii) la brecha responde de manera contemporánea a la inflación, pero no a la TPM, y (iii) la inflación no responde a ninguna de las otras dos variables de manera contemporánea.
- ▶ El VAR tiene un rezago.
- ▶ Como puede verse, el ejercicio es igual al discutido previamente en el curso, excepto por el método de estimación: Bayesiano en lugar de clásico.

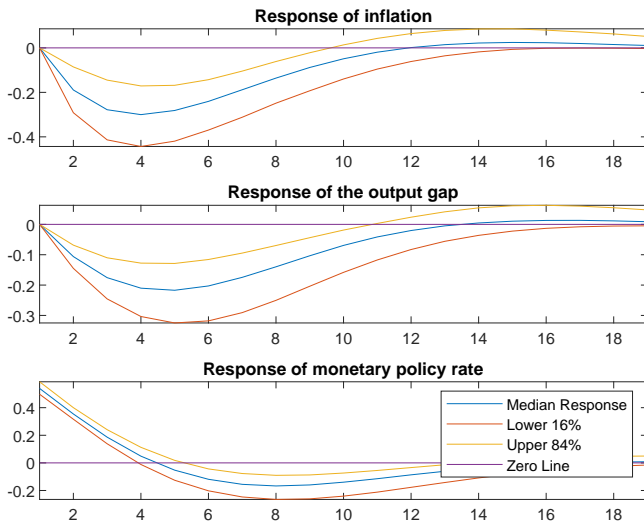
Aplicación 1: *Shocks* monetarios en Chile; identificación recursiva (2/4)

- ▶ Los datos para estimar el modelo son los siguientes:



Aplicación 1: *Shocks* monetarios en Chile; identificación recursiva (3/4)

- ▶ Respuesta a un *shock* de un desvío estándar a la TPM:



Aplicación 1: *Shocks* monetarios en Chile; identificación recursiva (4/4)

- ▶ La estimación Bayesiana del modelo arroja resultados similares a los de la estimación clásica:
 - Un *shock* típico a la TPM (un desvío estándar) en esta muestra hace que aumente en torno a 50 puntos base en impacto.
 - La contracción monetaria genera caídas graduales de la inflación y la actividad económica.
 - El efecto máximo del *shock* de política monetaria sobre la inflación y brecha del producto y el rezago con el que ocurre es similar al encontrado mediante estimación clásica.
- ▶ La razón por la que los resultados de la estimación Bayesiana son similares a los de la estimación clásica es que los *priors* son muy poco informativos (son “bastante amplios”).

Aplicación 2: *Shocks* monetarios en Chile; identificación por restricciones de signo (1/5)

- ▶ La idea de la identificación por restricciones de signo es admitir funciones impulso-respuesta (IRFs) con signos que son consistentes con la teoría económica.
- ▶ Por ejemplo, para identificar un *shock* de política monetaria, sería deseable que la inflación y la brecha del producto respondan de manera negativa a un *shock* que genera un aumento de la TPM.
- ▶ El algoritmo para ejecutar esta identificación consiste en “alterar” los elementos de una descomposición de Cholesky, generar IRFs, y verificar si satisfacen las restricciones de signo.

Aplicación 2: *Shocks* monetarios en Chile; identificación por restricciones de signo (2/5)

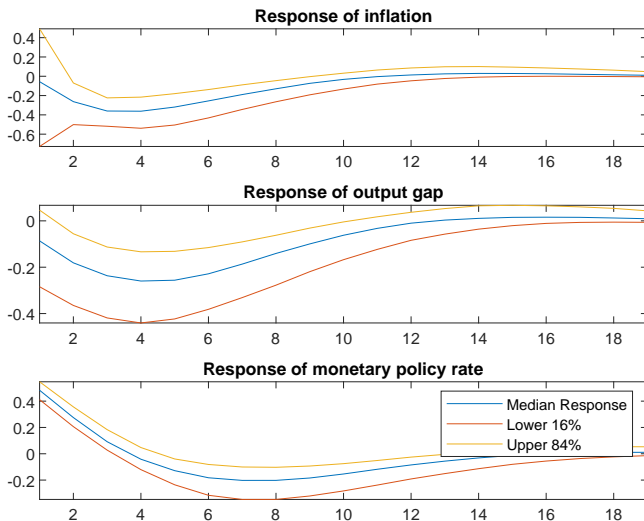
- ▶ Dentro del algoritmo de *Gibbs sampling*, después de pasar la etapa de iteraciones que se descartan (*burn-in*), los pasos que se siguen son los siguientes:
 - 1 De la distribución normal estándar, se obtiene una matriz K de dimensión $N \times N$.
 - 2 Se calcula la matriz Q de la descomposición QR de K . Según esta descomposición, Q es ortonormal, es decir, $Q'Q = I$.
 - 3 Se calcula la descomposición de Cholesky (\tilde{A}_0) de la matriz de varianza-covarianza (Σ) de la iteración actual del algoritmo de *Gibbs*. La descomposición de Cholesky satisface $\Sigma = \tilde{A}'_0 \tilde{A}_0$.
 - 4 Se calcula la matriz $A_0 = Q\tilde{A}_0$. Esta matriz con efectos contemporáneos se usa para generar IRFs (tal como se generan en el caso en que usamos solo la descomposición de Cholesky) y se evalúa si las IRFs satisfacen las restricciones de signo. Si lo hacen, se guardan. Si no, se descartan y se repiten estos pasos.

Aplicación 2: *Shocks* monetarios en Chile; identificación por restricciones de signo (3/5)

- ▶ Noten que en este procedimiento se altera la descomposición de Cholesky \tilde{A}_0 multiplicándola por Q para obtener A_0 , pero como Q es ortonormal, A_0 también satisface $\Sigma = A_0' A_0$, porque $A_0' A_0 = (Q \tilde{A}_0)' Q \tilde{A}_0 = \tilde{A}_0' Q' Q \tilde{A}_0 = \tilde{A}_0' I \tilde{A}_0 = \tilde{A}_0' \tilde{A}_0 = \Sigma$.
- ▶ En el análisis de *shocks* monetarios en Chile, vamos a retener las iteraciones cuyas IRFs satisfacen los siguientes criterios:
 - Un *shock* a la TPM hace que la TPM aumente en el periodo en que golpea a la economía y los siguientes dos periodos.
 - La inflación cae en respuesta a este *shock* en los dos trimestres después de que el *shock* golpea a la economía. La respuesta en el periodo en que el *shock* golpea se deja libre por la posibilidad de que se produzca un efecto “*price puzzle*” (que la inflación aumente al inicio).
 - La brecha del producto cae en los dos trimestres después de que el *shock* golpea a la economía, al igual que la inflación.

Aplicación 2: *Shocks* monetarios en Chile; identificación por restricciones de signo (4/5)

- ▶ Respuesta a un *shock* de un desvío estándar a la TPM:



Aplicación 2: *Shocks* monetarios en Chile; identificación por restricciones de signo (5/5)

- ▶ La estimación de los efectos de un *shock* a la TPM por restricciones de signo y mediante técnicas Bayesianas es razonablemente similar a la anterior.
- ▶ A diferencia de la identificación por estructura recursiva, en este caso la inflación y la brecha pueden responder libremente en el periodo en que el *shock* golpea a la economía (en la identificación por estructura recursiva, la inflación y la brecha no responden de manera contemporánea a la TPM por construcción).

Apéndice A (1/2)

- ▶ $Y_t = X_t B + v_t$ puede escribirse como $y_t = (I_N \otimes X_t)b + V_t$, donde $y_t = \text{vec}(Y_t)$, $b = \text{vec}(B)$, $V_t = \text{vec}(v_t)$.
- ▶ Usemos el ejemplo de dos variables (π_t, R_t) y dos rezagos.

$$y_t = (I_N \otimes X_t)b + V_t,$$

$$\begin{bmatrix} \pi_t \\ R_t \end{bmatrix} = \left(\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \otimes [1 \quad \pi_{t-1} \quad R_{t-1} \quad \pi_{t-2} \quad R_{t-2}] \right) \begin{bmatrix} c_\pi \\ b_{11} \\ b_{12} \\ d_{11} \\ d_{12} \\ c_R \\ b_{21} \\ b_{22} \\ d_{21} \\ d_{22} \end{bmatrix} + \begin{bmatrix} v_{\pi t} \\ v_{Rt} \end{bmatrix},$$

Apéndice A (2/2)

$$\begin{bmatrix} \pi_t \\ R_t \end{bmatrix} = \begin{bmatrix} 1 & \pi_{t-1} & R_{t-1} & \pi_{t-2} & R_{t-2} & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & \pi_{t-1} & R_{t-1} & \pi_{t-2} & R_{t-2} \end{bmatrix} \begin{bmatrix} c_\pi \\ b_{11} \\ b_{12} \\ d_{11} \\ d_{12} \\ c_R \\ b_{21} \\ b_{22} \\ d_{21} \\ d_{22} \end{bmatrix} + \begin{bmatrix} v_{\pi t} \\ v_{Rt} \end{bmatrix}.$$

$$\begin{bmatrix} \pi_t \\ R_t \end{bmatrix} = \begin{bmatrix} c_\pi + b_{11}\pi_{t-1} + b_{12}R_{t-1} + d_{11}\pi_{t-2} + d_{12}R_{t-2} \\ c_R + b_{21}\pi_{t-1} + b_{22}R_{t-1} + d_{21}\pi_{t-2} + d_{22}R_{t-2} \end{bmatrix} + \begin{bmatrix} v_{\pi t} \\ v_{Rt} \end{bmatrix}.$$