



UNIDAD III:
VECTORES AUTOREGRESIVOS
(MODELOS VAR)

DR. ROGER ALEJANDRO BANEGAS RIVERO, *PH.D.*

Modelos de Vectores Autoregresivos (VAR)

- Modelos autoregresivos es una propuesta generalizada por Sims (1980).
- Un modelo VAR es en esencia un sistema de modelos de regresión con variables predeterminadas. Ej. Existen más de una variable dependiente.

- El caso más simple es un VAR bivariado:

$$y_{1t} = \beta_{10} + \beta_{11}y_{1t-1} + \dots + \beta_{1k}y_{1t-k} + \alpha_{11}y_{2t-1} + \dots + \alpha_{1k}y_{2t-k} + u_{1t}$$

$$y_{2t} = \beta_{20} + \beta_{21}y_{2t-1} + \dots + \beta_{2k}y_{2t-k} + \alpha_{21}y_{1t-1} + \dots + \alpha_{2k}y_{1t-k} + u_{2t}$$

Donde u_{it} está iid con $E(u_{it})=0, i=1,2; E(u_{1t} u_{2t})=0$.

- Este análisis se puede extender a un modelo VAR(g), de tal forma que existen g variables endógenas en g ecuaciones.

Modelos de Vectores Autoregresivos (VAR)

Notación y conceptos

- Un aspecto importante de modelos VARs es la abreviación de su notación. Por ejemplo, considere que existe un vector de variable endógenas con un rezago $p=1$.

$$y_{1t} = \beta_{10} + \beta_{11}y_{1t-1} + \alpha_{11}y_{2t-1} + u_{1t}$$

- Se reescribe como: $y_{2t} = \beta_{20} + \beta_{21}y_{2t-1} + \alpha_{21}y_{1t-1} + u_{2t}$

$$\begin{pmatrix} y_{1t} \\ y_{2t} \end{pmatrix} = \begin{pmatrix} \beta_{10} \\ \beta_{20} \end{pmatrix} + \begin{pmatrix} \beta_{11} & \alpha_{11} \\ \alpha_{21} & \beta_{21} \end{pmatrix} \begin{pmatrix} y_{1t-1} \\ y_{2t-1} \end{pmatrix} + \begin{pmatrix} u_{1t} \\ u_{2t} \end{pmatrix}$$

de una manera más compacta se reescribe como VAR(p) o VAR(1):

$$\begin{matrix} y_t & = & \beta_0 & + & \beta_1 & y_{t-1} & + & u_t \\ g \times 1 & & g \times 1 & & g \times g & g \times 1 & & g \times 1 \end{matrix}$$

Modelos de Vectores Autoregresivos (VAR)

Notación y conceptos (cont'd)

- Este modelo se puede extender en p rezagos para cada variable incluida en cada ecuación:

$$y_t = \beta_0 + \beta_1 y_{t-1} + \beta_2 y_{t-2} + \dots + \beta_p y_{t-p} + u_t$$

$$g \times 1 \quad g \times 1 \quad g \times g \quad g \times 1 \quad g \times g \quad g \times 1 \quad g \times g \quad g \times 1 \quad g \times 1$$

- Se puede extender este caso para un modelo con variables en diferencias (corto plazo) y relaciones de cointegración (largo plazo): el llamado vector con corrector de errores (VECM).
- Los modelos VAR están especificados con variables estacionarias.

Modelos VAR comparado con ecuaciones estructurales

- **Ventajas de los modelos VAR**

- No necesita especificar cuales son endógenas o exógenas: todas son endógenas.
- Tiene mayores ventajas que los modelos ARIMA: pueden intervenir otras variables exógenas.
- Se asume que no existen efectos simultáneos: se puede aplicar de forma separada MCO para cada ecuación.
- Los pronósticos de modelos VAR son frecuentemente mejores que los modelos estructurales.

- **Problemas con modelos VAR**

- Modelos VARs son atóxicos (al igual que los modelos ARIMA)
- ¿Cómo se decide el tamaño óptimo del rezago?
- Muchos parámetros! Si se tienen g ecuaciones para g variables y se tienen p rezagos en cada ecuación, se tiene que estimar $(g + pg^2)$ parámetros. e.d. $g=3$, $p=3$, número de parámetros = 30.
- ¿Se debe asegurar que todos los componentes VAR son estacionarios?
- ¿Cómo se interpretan los coeficientes?

Escogiendo el tamaño óptimo de rezago para un VAR

- 2 enfoques posibles: restricciones entre ecuaciones y criterios de información.

Restricciones entre ecuaciones.

- En el espíritu de modelos VAR(irrestringido) , cada ecuación debe tener el mismo tamaño de rezago.
- Suponga un modelo bivariado VAR(8) que se estima con base en 8 rezagos para cada ecuación, y se quiere examinar que 4 de 8 son cero de forma conjunta. Esto se realiza mediante la razón de verosimilitud (LR)
- Se denota una matriz residual de varianza - covarianza(dado por $\hat{u}\hat{u}' / T$), como $\hat{\Sigma}$. La razón de verosimilitud se prueba por:

$$LR = T \left[\log |\hat{\Sigma}_r| - \log |\hat{\Sigma}_u| \right]$$

Escogiendo el tamaño óptimo de rezago para un VAR (cont'd)

- Donde $\hat{\Sigma}_r$ es la matriz residual de varianza-covarianza restringida (4 rezagos), $\hat{\Sigma}_u$ es la matriz residual de varianza-covarianza irrestricta (8 rezagos) y T es el tamaño de la muestra.
- La prueba estadística está asintóticamente distribuida con una χ^2 con grados de libertad igual al número total de restricciones.. En el modelo VAR se están restringiendo 4 rezagos para dos variables en cada una de las dos ecuaciones:
= un total de $4 * 2 * 2 = 16$ restricciones.
- En el caso general se tienen un VAR con g ecuaciones, y se quiere imponer la restricción que q rezagos son iguales a cero; en consecuencia, se tendría g^2q restricciones de forma conjunta.
- Desventajas: conduciendo la prueba LR es tediosa y requiere distribución normal en los residuos.

Criterios de información para el tamaño del rezago VAR

- Se aplican versiones multivariadas de criterios de información, lo cual se puede definir a través de:

$$MAIC = \ln |\hat{\Sigma}| + 2k' / T$$

$$MSBIC = \ln |\hat{\Sigma}| + \frac{k'}{T} \ln(T)$$

$$MHQIC = \ln |\hat{\Sigma}| + \frac{2k'}{T} \ln(\ln(T))$$

k' es el número total de regresores en todas las ecuaciones, que será igual a $g^2k + g$ para g ecuaciones, cada uno con k rezagos de las variables g , más un término constante en cada ecuación. Estos valores se construyen para 0, 1, ... rezagos (se determina un número máximo rezago preestablecido \bar{k}).

¿Modelos VAR incluye términos contemporáneos?

- Si se asume un VAR de la forma:

$$y_{1t} = \beta_{10} + \beta_{11}y_{1t-1} + \alpha_{11}y_{2t-1} + u_{1t}$$

$$y_{2t} = \beta_{20} + \beta_{21}y_{2t-1} + \alpha_{21}y_{1t-1} + u_{2t}$$

- ¿Qué sucede si se añaden términos simultáneos o contemporáneos?

$$y_{1t} = \beta_{10} + \beta_{11}y_{1t-1} + \alpha_{11}y_{2t-1} + \alpha_{12}y_{2t} + u_{1t}$$

$$y_{2t} = \beta_{20} + \beta_{21}y_{2t-1} + \alpha_{21}y_{1t-1} + \alpha_{22}y_{1t} + u_{2t}$$

- Se puede escribir como:

$$\begin{pmatrix} y_{1t} \\ y_{2t} \end{pmatrix} = \begin{pmatrix} \beta_{10} \\ \beta_{20} \end{pmatrix} + \begin{pmatrix} \beta_{11} & \alpha_{11} \\ \alpha_{21} & \beta_{21} \end{pmatrix} \begin{pmatrix} y_{1t-1} \\ y_{2t-1} \end{pmatrix} + \begin{pmatrix} \alpha_{12} & 0 \\ 0 & \alpha_{22} \end{pmatrix} \begin{pmatrix} y_{2t} \\ y_{1t} \end{pmatrix} + \begin{pmatrix} u_{1t} \\ u_{2t} \end{pmatrix}$$

- Esta es la forma primitiva del modelo VAR.

VAR forma primitiva vs. VAR forma estándar

- Se puede llevar a la parte izquierda:

$$\begin{pmatrix} 1 & -\alpha_{12} \\ -\alpha_{22} & 1 \end{pmatrix} \begin{pmatrix} y_{1t} \\ y_{2t} \end{pmatrix} = \begin{pmatrix} \beta_{10} \\ \beta_{20} \end{pmatrix} + \begin{pmatrix} \beta_{11} & \alpha_{11} \\ \alpha_{21} & \beta_{21} \end{pmatrix} \begin{pmatrix} y_{1t-1} \\ y_{2t-1} \end{pmatrix} + \begin{pmatrix} u_{1t} \\ u_{2t} \end{pmatrix}$$

o

$$\mathbf{B} y_t = \beta_0 + \beta_1 y_{t-1} + u_t$$

- Se puede multiplicar a ambos lados por \mathbf{B}^{-1} , lo cual implica:

$$y_t = \mathbf{B}^{-1}\beta_0 + \mathbf{B}^{-1}\beta_1 y_{t-1} + \mathbf{B}^{-1}u_t$$

o

$$y_t = \mathbf{A}_0 + \mathbf{A}_1 y_{t-1} + e_t$$

- Esta es la forma estándar VAR, que se puede estimar mediante MCO.

Significancia en bloque y prueba de causalidad

- Un modelo VAR incluye varios rezagos de las variables, es difícil distinguir cual es significativa y cuál no. Para ilustración considere un modelo bivarido VAR(3):

$$\begin{pmatrix} y_{1t} \\ y_{2t} \end{pmatrix} = \begin{pmatrix} \alpha_{10} \\ \alpha_{20} \end{pmatrix} + \begin{pmatrix} \beta_{11} & \beta_{12} \\ \beta_{21} & \beta_{22} \end{pmatrix} \begin{pmatrix} y_{1t-1} \\ y_{2t-1} \end{pmatrix} + \begin{pmatrix} \gamma_{11} & \gamma_{12} \\ \gamma_{21} & \gamma_{22} \end{pmatrix} \begin{pmatrix} y_{1t-2} \\ y_{2t-2} \end{pmatrix} + \begin{pmatrix} \delta_{11} & \delta_{12} \\ \delta_{21} & \delta_{22} \end{pmatrix} \begin{pmatrix} y_{1t-3} \\ y_{2t-3} \end{pmatrix} + \begin{pmatrix} u_{1t} \\ u_{2t} \end{pmatrix}$$

- Este VAR se puede expresar a través de ecuaciones individuales:

$$y_{1t} = \alpha_{10} + \beta_{11}y_{1t-1} + \beta_{12}y_{2t-1} + \gamma_{11}y_{1t-2} + \gamma_{12}y_{2t-2} + \delta_{11}y_{1t-3} + \delta_{12}y_{2t-3} + u_{1t}$$

$$y_{2t} = \alpha_{20} + \beta_{21}y_{1t-1} + \beta_{22}y_{2t-1} + \gamma_{21}y_{1t-2} + \gamma_{22}y_{2t-2} + \delta_{21}y_{1t-3} + \delta_{22}y_{2t-3} + u_{2t}$$

-
- Se está interesado en las pruebas de hipótesis en una forma matricial.

Significancia en bloque y prueba de causalidad(cont'd)

Hypothesis	Implied Restriction
1. Lags of y_{1t} do not explain current y_{2t}	$\beta_{21} = 0$ and $\gamma_{21} = 0$ and $\delta_{21} = 0$
2. Lags of y_{1t} do not explain current y_{1t}	$\beta_{11} = 0$ and $\gamma_{11} = 0$ and $\delta_{11} = 0$
3. Lags of y_{2t} do not explain current y_{1t}	$\beta_{12} = 0$ and $\gamma_{12} = 0$ and $\delta_{12} = 0$
4. Lags of y_{2t} do not explain current y_{2t}	$\beta_{22} = 0$ and $\gamma_{22} = 0$ and $\delta_{22} = 0$

- Se puede aplicar la prueba F -test para cada ecuación.
- Lo anterior es la llamada Causalidad de Granger.
- La causalidad de Granger busca las siguientes respuestas“¿Los cambios en y_1 causan cambios en y_2 ?” Si y_1 causa a y_2 , los rezagos de y_1 deberían ser significativos en y_2 . En este caso, se dice que y_1 “causa Granger” y_2 .
- Si y_2 causa y_1 , los rezagos de y_2 deberían ser significativos para y_1 .
- Si ambos rezagos son significativos, se dice que existe “una causalidad bi-direccional”

Funciones de impulso-respuesta

- Los modelos VAR son difíciles de interpretar: una solución es construir funciones de impulso-respuesta y descomposición de varianza
- Las funciones de impulso-respuesta explican la respuesta de cada variable dependiente del VAR a un *shock* en el término de error. Un *shock* único es aplicado a cada variable dependiente del modelo VAR.
- Considere un modelo bivariado VAR(1):

$$y_{1t} = \beta_{10} + \beta_{11}y_{1t-1} + \alpha_{11}y_{2t-1} + u_{1t}$$

$$y_{2t} = \beta_{20} + \beta_{21}y_{2t-1} + \alpha_{21}y_{1t-1} + u_{2t}$$

- Un cambio en u_{1t} cambiará inmediatamente y_1 , cambiará y_2 y también y_1 durante el período siguiente.
- Se puede examinar cuánto durará el impacto del *shock* en cada ecuación y sobre todas las variables del sistema.

Descomposición de la varianza

- La descomposición de varianza ofrece una manera diferente de examinar la dinámica VAR. Proporciona información de cambios en la variable dependiente debido a sus propios “*schoks*” versus “*shocks*” de otras variables.
- Sinónimos de *shocks*: choques, innovaciones, perturbaciones o impulsos.
- Lo anterior se consigue al determinar que tanto de los errores pronosticados de la varianza, en s -pasos hacia adelante, es explicada por las innovaciones de cada variable incluida en el sistema VAR:
- La descomposición de varianza brinda información acerca de la importancia relativa de cada *shock* entre las variables del modelo VAR.

Funciones de impulso-respuesta y la descomposición de varianza

La ordenación de las variables

- Para realizar funciones de impulso-respuesta y descomposición de la varianza, el orden en la ordenación de las variables es importante.
- Desde que los signos de los coeficientes pueden ser positivos o negativos, estadísticamente significativos o no, la interpretación de modelos VAR es difícil: ¿cómo reacciona una variable frente a cambios, innovaciones o choques de otras variables?
- Se utiliza el análisis de impulso-respuesta en s-pasos hacia adelante.
- En la ordenación de impulso-respuesta Cholesky, se asume que la primera variable es exógena y las que siguen son endógenas.
- La realización de impulso-respuesta mediante una especificación *generalizada* la ordenación de las variables no influye .

Funciones de impulso-respuesta y la descomposición de varianza

La ordenación de las variables

- Lo anterior se basa en que los errores del modelo VAR no están relacionados.
- Sin embargo, lo anterior no es cierto. Los errores están frecuentemente relacionados: tienen un mismo componente..
- Lo que se tiene que hacer es “ortogonalizar” las innovaciones.
- En un VAR bivariado, este problema se puede atribuir a patrones comunes en el modelo VAR.
- En el caso más general, la ortoganilización es más compleja pero la interpretación es la misma.