

Estimación MC2E, MVIL en Modelos de Ecuaciones Simultáneas

OCW 2013 Marta Regúlez Castillo

Economía Aplicada III (UPV/EHU)

OCW 2013

Contents

- 1 Mínimos Cuadrados en 2 Etapas
- 2 Máxima Verosimilitud Información Limitada (MVIL)

Mínimos Cuadrados en 2 Etapas

- El método de Mínimos Cuadrados en dos Etapas (MC2E) también es un método de estimación de Modelos de Ecuaciones Simultáneas con información limitada.
- Esta técnica de estimación está indicada tanto si la ecuación está exactamente identificada como si está sobreidentificada.
- Se puede considerar como un método de estimación por Variables Instrumentales y en el caso de exacta identificación MC2E coincide con MCI. La demostración está cubierta en las lecturas recomendadas.

Mínimos Cuadrados en 2 Etapas

Consideremos la j -ésima ecuación estructural del Modelo de Ecuaciones Simultáneas, después de haberle impuesto todas las restricciones a priori y el convenio de normalización.

$$\underbrace{\mathbf{y}_j}_{T \times 1} = \underbrace{\mathbf{Y}_j}_{T \times G_j} \underbrace{\boldsymbol{\beta}_j}_{G_j \times 1} + \underbrace{\mathbf{X}_j}_{T \times K_j} \underbrace{\boldsymbol{\gamma}_j}_{K_j \times 1} + \underbrace{\mathbf{u}_j}_{T \times 1}$$

o de forma más compacta

$$\underbrace{\mathbf{y}_j}_{T \times 1} = \underbrace{\mathbf{Z}_j}_{T \times (G_j + K_j)} \underbrace{\boldsymbol{\delta}_j}_{(G_j + K_j) \times 1} + \underbrace{\mathbf{u}_j}_{T \times 1} \quad \mathbf{u}_j \sim (\mathbf{0}, \sigma_j^2 I_T)$$

$$\text{donde } \mathbf{Z}_j = \begin{bmatrix} \underbrace{\mathbf{Y}_j}_{T \times G_j} & \underbrace{\mathbf{X}_j}_{T \times K_j} \end{bmatrix} \quad \boldsymbol{\delta}_j = \begin{bmatrix} \boldsymbol{\beta}_j \\ \boldsymbol{\gamma}_j \end{bmatrix}.$$

Mínimos Cuadrados en 2 Etapas

El método de MC2E, como su propio nombre indica, se puede llevar a cabo en dos etapas realizando una estimación por MCO en cada etapa:

- **1ª Etapa:** Se realiza la regresión de cada variable endógena en Y_j sobre **todas** las variables exógenas o predeterminadas del modelo. Esto es, se estima la forma reducida para Y_j :

$$\underbrace{Y_j}_{T \times G_j} = \underbrace{X}_{T \times K} \underbrace{\Pi'_j}_{K \times G_j} + \underbrace{V_j}_{T \times G_j} \longrightarrow \hat{\Pi}'_{jMCO} = (X'X)^{-1}X'Y_j$$

$\hat{\Pi}'_{jMCO} = \left[\hat{\pi}_1^{MCO} \dots \hat{\pi}_{G_j}^{MCO} \right]$, donde las columnas de $\hat{\Pi}'_{jMCO}$ son respectivamente los coeficientes de la regresión de cada variable en Y_j sobre X . Se obtienen los valores ajustados de Y_j dada la estimación de la forma reducida

$$\hat{Y}_j = X(X'X)^{-1}X'Y_j$$

Mínimos Cuadrados en 2 Etapas

- **2ª Etapa** Se realiza la regresión de \mathbf{y}_j sobre \hat{Y}_j y X_j .

Si denotamos la matriz de regresores de esta segunda regresión como $\hat{Z}_j = \begin{pmatrix} \hat{Y}_j & X_j \end{pmatrix}$, el estimador resultante de δ_j sería solución al sistema de ecuaciones normales

$$\left(\hat{Z}_j' \hat{Z}_j \right) \hat{\delta}_j^{MC2E} = \hat{Z}_j' \mathbf{y}_j$$

$$\begin{pmatrix} \hat{Y}_j' \hat{Y}_j & \hat{Y}_j' X_j \\ X_j' \hat{Y}_j & X_j' X_j \end{pmatrix} \begin{pmatrix} \hat{\beta}_j^{MC2E} \\ \hat{\gamma}_j^{MC2E} \end{pmatrix} = \begin{pmatrix} \hat{Y}_j' \mathbf{y}_j \\ X_j' \mathbf{y}_j \end{pmatrix}$$

Mínimos Cuadrados en 2 Etapas

En la matriz $\hat{Z}_j = \begin{pmatrix} \hat{Y}_j & X_j \end{pmatrix}$ todas las columnas son funciones lineales de las K columnas de X .

- Si la ecuación satisface la condición de rango para la identificación, y por lo tanto también la de orden ($K \geq G_j + K_j$), la matriz $\begin{pmatrix} \hat{Z}_j' & \hat{Z}_j \end{pmatrix}$ será de rango completo e invertible. El sistema tendrá una única solución,

$$\hat{\delta}_j^{MC2E} = \begin{pmatrix} \hat{Z}_j' & \hat{Z}_j \end{pmatrix}^{-1} \hat{Z}_j' \mathbf{y}_j$$

- Si la ecuación no está identificada, bien porque no se satisface la de orden o, aunque esta se satisfaga, porque no se satisface la de rango, el estimador $\hat{\delta}_j^{MC2E}$ no está bien definido. La matriz $\begin{pmatrix} \hat{Z}_j' & \hat{Z}_j \end{pmatrix}$ es de rango reducido por lo que no existe su inversa.

Mínimos Cuadrados en 2 Etapas

Dado que $P_X = X(X'X)^{-1}X'$ y $P_X X_j = X_j$ se tiene

$$\hat{Z}_j = [\hat{Y}_j \ X_j] = [X(X'X)^{-1}X'Y_j \ X_j] = [P_X Y_j \ P_X X_j] = P_X [Y_j \ X_j] = P_X Z_j$$

Utilizando este resultado podemos obtener que el estimador MC2E es un estimador de VI con matriz de instrumentos $\hat{Z}_j = [\hat{Y}_j \ X_j]$,

$$\hat{\delta}_j^{MC2E} = (\hat{Z}_j' \hat{Z}_j)^{-1} \hat{Z}_j' \mathbf{y}_j = \left(Z_j' \underbrace{P_X}_{P_X P_X} Z_j \right)^{-1} Z_j' \underbrace{P_X}_{P_X P_X} \mathbf{y}_j = (\hat{Z}_j' Z_j)^{-1} \hat{Z}_j' \mathbf{y}_j$$

y la siguiente forma de obtener el estimador MC2E de δ_j ,

$$\hat{\delta}_j^{MC2E} = \left(Z_j' X (X'X)^{-1} X' Z_j \right)^{-1} Z_j' X (X'X)^{-1} X' \mathbf{y}_j$$

Máxima Verosimilitud Información Limitada

- El método de estimación por Máxima Verosimilitud Información Limitada (MVIL) también está dentro de la clase de estimadores con información Limitada.
- Considera la estimación de los parámetros estructurales de una ecuación, teniendo en cuenta solamente la función de verosimilitud de las variables endógenas de esa ecuación y las restricciones de identificación correspondientes a la ecuación a estimar.
- No se tiene en cuenta en la verosimilitud el resto de variables endógenas del sistema ni las restricciones de identificación impuestas en otras ecuaciones.

Máxima Verosimilitud Información Limitada

Consideremos la ecuación j -ésima a estimar antes de imponer la normalización ($\beta_{jj} = 1$)

$$\beta_{jj} \underbrace{\mathbf{y}_j}_{T \times 1} = \underbrace{\mathbf{Y}_j}_{T \times G_j} \underbrace{\beta_j}_{G_j \times 1} + \underbrace{\mathbf{X}_j}_{T \times K_j} \underbrace{\gamma_j}_{K_j \times 1} + \underbrace{\mathbf{u}_j}_{T \times 1}$$

$$\underbrace{\begin{bmatrix} \mathbf{y}_j & \mathbf{Y}_j \end{bmatrix}}_{T \times (G_j+1)} \underbrace{\begin{bmatrix} \beta_{jj} \\ -\beta_j \end{bmatrix}}_{(G_j+1) \times 1} = \underbrace{\mathbf{X}_j}_{T \times K_j} \underbrace{\gamma_j}_{K_j \times 1} + \mathbf{u}_j \quad \Leftrightarrow \quad \mathbf{Y}_j^+ \beta_j^+ = \mathbf{X}_j \gamma_j + \mathbf{u}_j$$

Las ecuaciones de la Forma Reducida para \mathbf{Y}_j^+ son las siguientes

$$\underbrace{\mathbf{Y}_j^+}_{T \times (G_j+1)} = \underbrace{\mathbf{X}_j}_{T \times K_j} \underbrace{\Pi_{1j}^+}_{K_j \times (G_j+1)} + \underbrace{\mathbf{X}_j^*}_{T \times K_j^*} \underbrace{\Pi_{2j}^+}_{K_j^* \times (G_j+1)} + \underbrace{\mathbf{V}_j^+}_{T \times (G_j+1)}$$

Máxima Verosimilitud Información Limitada

Senotamos por \mathbf{y}_{jt}^+ y \mathbf{x}_{jt}^+ a la fila t-ésima de Y_j^+ y de X respectivamente y por \mathbf{v}_{jt}^+ al vector ($1 \times (G_j + 1)$) correspondiente a la fila t-ésima de la matriz V_j^+ .

$$\mathbf{y}_{jt}^+ = \Pi_j^{+'} \mathbf{x}_{jt}^+ + \mathbf{v}_{jt}^+ \iff \mathbf{y}_{jt}^+ - \mathbf{x}_{jt}^+ \Pi_j^+ = \mathbf{v}_{jt}^+$$

Dado el supuesto sobre la distribución de los errores estructurales $\mathbf{u}_t \sim NID(\mathbf{0}, \Sigma)$, el vector de errores de la forma reducida correspondiente a las ecuaciones de las variables Y_j^+ en el momento t, se distribuye $\mathbf{v}_{jt}^+ \sim NID(\mathbf{0}, \Omega_j^+)$ donde Ω_j^+ es la submatriz correspondiente de Ω .

Máxima Verosimilitud Información Limitada

La función de verosimilitud de Y_j^+ es:

$$L_j = L(\Pi_j^+, \Omega_j^+; Y_j^+, X) = \prod_{t=1}^T L(\Pi_j^+, \Omega_j^+; \mathbf{y}_{jt}^+, \mathbf{x}_{jt}^+) =$$

$$= \prod_{t=1}^T \left((2\pi)^{-(G_j+1)/2} |\Omega_j^+|^{-1/2} \exp(-1/2) (\mathbf{y}_{jt}^+ - \mathbf{x}_{jt}^+ \Pi_j^+)' (\Omega_j^+)^{-1} (\mathbf{y}_{jt}^+ - \mathbf{x}_{jt}^+ \Pi_j^+) \right)$$

$$\ln L_j = -(T(G_j+1)/2) \ln 2\pi - T/2 \ln |\Omega_j^+| - 1/2 \left[\sum_{t=1}^T (\mathbf{y}_{jt}^+ - \mathbf{x}_{jt}^+ \Pi_j^+)' (\Omega_j^+)^{-1} (\mathbf{y}_{jt}^+ - \mathbf{x}_{jt}^+ \Pi_j^+) \right]$$

El estimador por máxima verosimilitud MVIL maximiza esta función sujeto a las restricciones que relacionan los parámetros estructurales de la ecuación j -ésima con los parámetros de la forma reducida.

Máxima Verosimilitud Información Limitada

De las restricciones de exclusión de la ecuación j -ésima y la relación entre los parámetros de la F.E. y la F.R. obtenemos las siguientes ecuaciones:

$$\Pi_{1j}^{+'} \beta_j^+ = \gamma_j \quad K_j \text{ ecuaciones} \quad (1)$$

$$\Pi_{2j}^{+'} \beta_j^+ = \mathbf{0} \quad K_j^* \text{ ecuaciones} \quad (2)$$

Las primeras K_j ecuaciones sólo muestran cómo obtener γ_j dado β_j^+ . Si podemos resolver para β_j^+ de (2), podemos utilizar esta solución en (1) para obtener γ_j y por lo tanto, los parámetros estructurales de la ecuación j estarán identificados.

La condición de Rango para la identificación de la ecuación establece que $\text{rango}(\Pi_{2j}^{+'}) = G_j$. La condición necesaria es que $G_j \geq K_j^*$.

Máxima Verosimilitud Información Limitada

Hay tres casos a considerar:

- La ecuación está exactamente identificada. No hay restricciones sobre Π_{j2}^+ . Dada la normalización

$$\pi_j^* - \Pi_{1j}^{*'} \beta_j = \mathbf{0} \implies \beta_j = (\Pi_{1j}^{*'})^{-1} \pi_j^*$$

ya que la matriz $\Pi_{1j}^{*'}$ es cuadrada y de rango completo por lo que existe su inversa. El estimador de β_j y γ_j por MVIL se obtiene de

$$\hat{\beta}_j^{MVIL} = (\hat{\Pi}_{1j}^{*'})^{-1} \hat{\pi}_j^*$$

$$\hat{\gamma}_j = \hat{\pi}_j - \hat{\Pi}_{1j}^{*' } \hat{\beta}_j^{MVIL}$$

siendo el estimador de Π_j^+ que maximiza el logaritmo de la verosimilitud el estimador MCO. El estimador de β_j y γ_j por MVIL coincide con MCI y entonces también con MC2E.

Máxima Verosimilitud Información Limitada

- La ecuación no está identificada. No hay estimación posible. No podemos recuperar los parámetros estructurales a partir de los parámetros de la Forma Reducida.
- La ecuación esta sobreidentificada.
 - La sobreidentificación impone restricciones sobre Π_j^+ . Las restricciones (2) son importantes.
 - En este caso la solución analítica al problema de maximizar $\ln L_j$ sujeto a $\Pi_{j2}^{+'} \beta_j^+ = \mathbf{0}$ con respecto a Π_j^+ , β_j^+ y Ω_j^+ es extremadamente larga y complicada.

Máxima Verosimilitud Información Limitada

El estimador MVIL de β_j^+ coincide con el estimador que minimiza el siguiente ratio de varianzas residuales:

$$l = \frac{\beta_j^{+'} A \beta_j^+}{\beta_j^{+'} S \beta_j^+} = \frac{\beta_j^{+'} Y_j^{+'} M_j Y_j^+ \beta_j^+}{\beta_j^{+'} Y_j^{+'} M Y_j^+ \beta_j^+}$$

siendo $M_j = I_T - X_j(X_j'X_j)^{-1}X_j'$ y $M = I_T - X(X'X)^{-1}X'$.

- El numerador del ratio de varianzas l es la suma de cuadrados residual de la regresión de $\tilde{y}_j \equiv Y_j^+ \beta_j^+$, dado β_j^+ , sobre las variables exógenas X_j que son las incluidas en la ecuación estructural a estimar

$$\underbrace{Y_j^+ \beta_j^+}_{\tilde{y}_j} = X_j \gamma_j + u_j$$

Máxima Verosimilitud Información Limitada

- El denominador del ratio de varianzas l es la suma de cuadrados residual de la regresión de $\tilde{y}_j \equiv Y_j^+ \beta_j^+$, dado β_j^+ , sobre todas las variables exógenas X .

Una vez obtenido el estimador de β_j^+ , impuesta la normalización, que minimiza ese ratio de varianzas residuales, $\hat{\beta}_j^{+'} = (1, -\hat{\beta}_j^{MVIL})$, el estimador MVIL de γ_j se puede obtener de resolver para $\hat{\gamma}_j$

$$X_j'(\mathbf{y}_j - Y_j \hat{\beta}_j^{MVIL}) = X_j' X_j \hat{\gamma}_j \quad \Rightarrow \quad \hat{\gamma}_j^{MVIL} = (X_j' X_j)^{-1} X_j'(\mathbf{y}_j - Y_j \hat{\beta}_j^{MVIL})$$

que es el resultado de la regresión de $(\mathbf{y}_j - Y_j \hat{\beta}_j^{MVIL})$ sobre X_j .

Máxima Verosimilitud Información Limitada

El estimador $\hat{\beta}_j^{MVIL}$ se puede obtener como sigue:

a) Calcular las matrices

$$S_j^0 = Y_j^{+'} M_j Y_j^+ = Y_j^{+'} (I_T - X_j (X_j' X_j)^{-1} X_j') Y_j^+ = E_j^{0'} E_j^0$$

$$S_j^1 = Y_j^{+'} M Y_j^+ = Y_j^{+'} (I_T - X (X' X)^{-1} X') Y_j^+ = E_j^{1'} E_j^1$$

Cada columna de $E_j^0 = M_j Y_j^+$ es el vector de residuos minimocuadráticos obtenidos de la regresión de la columna correspondiente de Y_j^+ sobre X_j .

Para $E_j^1 = M Y_j^+$ es lo mismo pero incluyendo en las regresiones también a X_j^* , esto es todas las variables exógenas X .

Máxima Verosimilitud Información Limitada

- b) Se obtienen las raíces características de la matriz $(S_j^1)^{-1} S_j^0$ o equivalentemente de la matriz $D = (S_j^1)^{-1/2} S_j^0 (S_j^1)^{-1/2}$.
 Todas las raíces son reales y mayores o iguales a la unidad.
 → Se elige la menor raíz característica λ_1
- c) Particionamos la matriz S_j^0 y S_j^1

$$S_j^0 = \begin{pmatrix} s_{jj}^0 & \mathbf{s}_j^{0'} \\ \underline{\mathbf{s}}_j^0 & S_{jj}^0 \end{pmatrix} \quad S_j^1 = \begin{pmatrix} s_{jj}^1 & \mathbf{s}_j^{1'} \\ \underline{\mathbf{s}}_j^1 & S_{jj}^1 \end{pmatrix}$$

Con estos elementos disponibles se puede obtener

$$\hat{\beta}_j^{MVIL} = [S_{jj}^0 - \lambda_1 S_{jj}^1]^{-1} (\mathbf{s}_j^0 - \lambda_1 \mathbf{s}_j^1)$$

Si la ecuación está identificada, puede demostrarse que $\lambda_1 = 1$, lo que conduce a que $MVIL = MCI = MC2E$.