PUBLICACIONES DE 4º CURSO

Grado: DERECHO-ADE

Asignatura: ECONOMETRÍA

Grupos: Único

Tema: ESQUEMA TEMA 2

Profesores: Inmaculada Villanúa

Departamento de ANÁLISIS ECONÓMICO

Curso Académico 2014/15



Tema 2: El Modelo Lineal General. Especificación y estimación.

- 3.1 Introducción e hipótesis del Modelo Lineal General.
- 3.2 Estimación por Mínimos Cuadrados Ordinarios (MCO) de los parámetros del modelo. Propiedades.
- 3.3Estimación por Máxima Verosimilitud (MV) de los parámetros del modelo. Propiedades.
- 3.4 Estimación por intervalo.
- 3.5 Modelo Lineal General en desviaciones.

3.1. INTRODUCCIÓN E HIPÓTESIS BÁSICAS DEL MODELO

El MLG puede escribirse como:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i$$

Alternativamente:

$$Y_i = \mathbf{x}_i' \mathbf{\beta} + u_i \quad (i = 1, 2, \dots T)$$

siendo
$$\mathbf{x}'_{i} = \begin{pmatrix} 1 \ X_{2i} \ X_{3i} \cdots X_{ki} \end{pmatrix} \mathbf{y} \ \mathbf{\beta} = \begin{pmatrix} \beta_{1} \\ \beta_{2} \\ \vdots \\ \beta_{k} \end{pmatrix}$$

Además, existe una **tercera forma** de expresar el MLG, de forma concisa, para todos los individuos de la muestra:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$$

$$\mathbf{y} = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_T \end{pmatrix}; \mathbf{X} = \begin{pmatrix} 1 & X_{21} & \cdots & X_{k1} \\ 1 & X_{22} & \cdots & X_{k2} \\ \vdots & \ddots & \vdots \\ 1 & X_{2T} & \cdots & X_{kT} \end{pmatrix}; \mathbf{u} = \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_T \end{pmatrix}$$

HIPÓTESIS DEL MODELO LINEAL GENERAL

Hipótesis 1: Tanto la variable endógena (*Y*) como las exógenas (X_2, \dots, X_k) son magnitudes cuyos correspondientes conjuntos de valores $(Y_1, \dots, Y_T), (X_{21}, \dots, X_{2T}), (X_{31}, \dots, X_{3T}), \dots, (X_{k1}, \dots, X_{kT})$ son el resultado de la observación de una muestra aleatoria simple de tamaño T.

Hipótesis 2: Relación lineal

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i$$
ó bien

$$y = X\beta + u$$

donde $x\beta$ es la parte sistemática, y u es la parte aleatoria.

Hipótesis 3: Esperanza matemática cero para cada una de las perturbaciones.

$$E(\mathbf{u}) = 0$$

El conjunto de variables individualmente irrelevantes se compensan en promedio, es decir, no actúan siempre en la misma dirección. Hipótesis 4: (homoscedasticidad y no autocorrelación): Todas las perturbaciones tienen la misma varianza y no presentan autocorrelación por pares.

$$V(\mathbf{u}) = E(\mathbf{u}\mathbf{u}') = \sigma^2 \mathbf{I}_{\mathbf{T}}$$

Hipótesis 5: Distribución normal de la perturbación aleatoria. Unida a las hipótesis 3 y 4 nos permite escribir:

$$\mathbf{u} \sim N(\mathbf{0}, \sigma^2 \mathbf{I}_{\mathbf{T}})$$

Función de densidad:

$$f\left(\mathbf{u}\right) = f\left(u_{1}, \dots, u_{T}\right) = \left(\frac{1}{2\pi\sigma^{2}}\right)^{T/2} \exp\left(-\frac{1}{2\sigma^{2}}\sum_{i=1}^{T}u_{i}^{2}\right)$$

Hipótesis 6: no hay ninguna restricción sobre los parámetros del modelo $(\beta_1, \beta_2, \dots, \beta_k, \sigma^2)$.

Hipótesis 7: la parte sistemática y la aleatoria son independientes.

$$C \operatorname{ov}(\mathbf{X}, \mathbf{u}) = 0$$

Supuesto más restrictivo: las X son fijas para muestras repetidas, esto es, los elementos de la matriz X son no estocásticos, fijos.

Hipótesis 8: El número de observaciones T ha de ser superior al número de parámetros k.

Hipótesis 9: Todas las variables explicativas son linealmente independientes (ausencia del multicolinealidad). Esto implica que el rengo de la matriz \mathbf{X} es k:

$$r(\mathbf{X}) = k$$

De aquí se deriva que:

$$r(\mathbf{X}'\mathbf{X}) = k \quad \mathbf{y} \ |\mathbf{X}'\mathbf{X}| \neq 0$$

Hipótesis 10 (hipótesis de convergencia):

$$\lim_{T\to\infty}\frac{\mathbf{X}'\mathbf{X}}{T}=\Sigma_{\mathbf{x}\mathbf{x}}$$

siendo $\boldsymbol{\Sigma}_{\mathbf{XX}}$ una matriz de constantes.

Una vez definidas las hipótesis, podemos concluir la distribución del vector correspondiente a la variable endógena:

$$\mathbf{y} \sim N(\mathbf{x}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_{\mathrm{T}})$$

CÁLCULO DIFERENCIAL EN NOTACIÓN MATRICIAL

• Derivada parcial de una combinación lineal

Si x y a son vectores de T variables y T constantes, respectivamente:

$$\mathbf{x} = \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_T \end{pmatrix}; \quad \mathbf{a} = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_T \end{pmatrix}$$

una combinación lineal de las T variables puede escribirse como:

$$\mathbf{x'a} = a_1 X_1 + a_2 X_2 + \dots + a_T X_T$$

Las derivadas parciales de la combinación lineal, con respecto a cada variable X_i serán:

$$\frac{\partial (\mathbf{a}'\mathbf{x})}{\partial X_{1}} = a_{1}$$

$$\frac{\partial (\mathbf{a}'\mathbf{x})}{\partial X_{2}} = a_{2}$$

$$\vdots$$

$$\frac{\partial (\mathbf{a}'\mathbf{x})}{\partial X_{T}} = a_{T}$$

Esto puede escribirse de forma concisa como:

$$\frac{\partial (\mathbf{a}'\mathbf{x})}{\partial \mathbf{x}} = \mathbf{a} = \frac{\partial (\mathbf{x}'\mathbf{a})}{\partial \mathbf{x}}$$

Si las derivadas las hacemos respecto a un vector fila \mathbf{X}' , entonces el resultado es un vector fila, esto es,

$$\frac{\partial (\mathbf{a}'\mathbf{x})}{\partial \mathbf{x}'} = \mathbf{a}' = \frac{\partial (\mathbf{x}'\mathbf{a})}{\partial \mathbf{x}'}$$

• Derivada parcial de una forma cuadrática

Una forma cuadrática se define a partir de un vector columna, por ejemplo de T elementos, y una matriz simétrica, de orden T. Utilizando el mismo vector **x** anterior:

$$\mathbf{x'Ax} = \begin{pmatrix} X_1 & X_2 & \cdots & X_T \end{pmatrix} \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1T} \\ a_{21} & a_{22} & \cdots & a_{2T} \\ \vdots & \vdots & \ddots & \vdots \\ a_{T1} & a_{T2} & \cdots & a_{TT} \end{pmatrix} \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_T \end{pmatrix}$$

$$= \sum_{i=1}^{T} a_{ii} X_i^2 + 2 \sum_{i \neq j} a_{ij} X_i X_j$$

Si derivamos parcialmente esta última expresión respecto a cada X_i , obtenemos:

$$\frac{\partial (\mathbf{x}'\mathbf{A}\mathbf{x})}{\partial X_{1}} = 2(a_{11}X_{1} + a_{12}X_{2} + \dots + a_{1T}X_{T})$$

$$\frac{\partial (\mathbf{x}'\mathbf{A}\mathbf{x})}{\partial X_{2}} = 2(a_{21}X_{1} + a_{22}X_{2} + \dots + a_{2T}X_{T})$$

$$\vdots$$

$$\frac{\partial (\mathbf{x}'\mathbf{A}\mathbf{x})}{\partial X_{T}} = 2(a_{1T}X_{1} + a_{2T}X_{2} + \dots + a_{TT}X_{T})$$

Si estos resultados los escribimos de conjuntamente en forma de vector columna, el resultado puede obtenerse también como:

$$\frac{\partial (\mathbf{x}' \mathbf{A} \mathbf{x})}{\partial \mathbf{x}} = 2\mathbf{A} \mathbf{x}$$

Si derivamos respecto \mathbf{X}' el resultado es un vector fila:

$$\frac{\partial (\mathbf{x}' \mathbf{A} \mathbf{x})}{\partial \mathbf{x}'} = 2\mathbf{x}' \mathbf{A}$$

3.2.- ESTIMACIÓN MCO DE LOS PARÁMETROS DEL MODELO. PROPIEDADES.

3.2.1.- PARÁMETROS DE POSICIÓN ESTIMACIÓN

Minimizar

$$S = \sum \hat{u}_{i}^{2} = \sum \left(Y_{i} - \hat{Y}_{i}\right)^{2} = \sum \left(Y_{i} - \hat{\beta}_{1} - \hat{\beta}_{2}X_{2i} - \dots - \hat{\beta}_{k}X_{ki}\right)^{2}$$

$$\frac{\partial S}{\partial \hat{\beta}_{1}} = 0 \Rightarrow -2\sum \left(Y_{i} - \hat{\beta}_{1} - \hat{\beta}_{2}X_{2i} - \dots - \hat{\beta}_{k}X_{ki}\right) = 0$$

$$\frac{\partial S}{\partial \hat{\beta}_{2}} = 0 \Rightarrow -2\sum \left(Y_{i} - \hat{\beta}_{1} - \hat{\beta}_{2}X_{2i} - \dots - \hat{\beta}_{k}X_{ki}\right)X_{2i} = 0$$

$$\dots$$

$$\frac{\partial S}{\partial \hat{\beta}_{i}} = 0 \Rightarrow -2\sum \left(Y_{i} - \hat{\beta}_{1} - \hat{\beta}_{2}X_{2i} - \dots - \hat{\beta}_{k}X_{ki}\right)X_{ki} = 0$$

Las ecuaciones normales resultantes son:

$$\sum Y_{i} = T \hat{\beta}_{1} + \hat{\beta}_{2} \sum X_{2i} + \dots + \hat{\beta}_{k} \sum X_{ki}$$

$$\sum Y_{i} X_{2i} = \hat{\beta}_{1} \sum X_{2i} + \hat{\beta}_{2} \sum X_{2i}^{2} + \dots + \hat{\beta}_{k} \sum X_{ki} X_{2i}$$

$$\dots$$

$$\sum Y_{i} X_{ki} = \hat{\beta}_{1} \sum X_{ki} + \hat{\beta}_{2} \sum X_{2i} X_{ki} + \dots + \hat{\beta}_{k} \sum X_{ki}^{2}$$

Una manera alternativa de obtener las ecuaciones normales: escribir la función objetivo en **notación matricial**:

$$\hat{\mathbf{y}} = \mathbf{X}\hat{\boldsymbol{\beta}}$$

$$\hat{u} = y - X \hat{\beta}$$

$$\sum \hat{u}_i^2 = \hat{\mathbf{u}}'\hat{\mathbf{u}}$$

Min
$$S = \hat{\mathbf{u}}'\hat{\mathbf{u}} = (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}) =$$

 $\mathbf{y}'\mathbf{y} - \mathbf{y}'\mathbf{X}\hat{\boldsymbol{\beta}} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} + \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{y}'\mathbf{y} - 2\hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} + \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}}$

$$\frac{\partial S}{\partial \hat{\beta}} = 0 \Rightarrow -2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = 0$$

$$\frac{\partial^2 S}{\partial \hat{\beta} \partial \hat{\beta}'} = 2\mathbf{X}'\mathbf{X} > 0 \quad (\text{mínimo})$$

Ecuaciones normales:

$$\mathbf{X}'\mathbf{y} = \mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}}$$

El vector de estimadores MCO:

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{Y})$$

$$\mathbf{X'X} = \begin{pmatrix} T & \sum X_{2i} & \cdots & \sum X_{ki} \\ \sum X_{2i} & \sum X_{2i}^2 & \cdots & \sum X_{2i} X_{ki} \\ \vdots & \vdots & \ddots & \vdots \\ \sum X_{ki} & \sum X_{ki} X_{2i} & \cdots & \sum X_{ki}^2 \end{pmatrix}$$

$$\mathbf{X'y} = egin{pmatrix} \sum_{i} Y_i \\ \sum_{i} X_{2i} Y_i \\ \vdots \\ \sum_{i} X_{ki} Y_i \end{pmatrix}$$

Propiedades derivadas de las ecuaciones normales:

$$\mathbf{X}'\hat{\mathbf{u}} = \mathbf{0}$$
$$\hat{\mathbf{v}}'\hat{\mathbf{u}} = 0$$

PROPIEDADES

> Propiedades para muestras finitas

a) Lineales

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} = \mathbf{A}'\mathbf{y}$$

siendo $\bf A$ una matriz de orden $k \times T$, que podemos escribir como:

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1T} \\ a_{21} & a_{22} & \cdots & a_{2T} \\ \cdots & \cdots & \ddots & \cdots \\ a_{k1} & a_{k2} & \cdots & a_{kT} \end{pmatrix}$$

$$\mathbf{A'y} = egin{pmatrix} a_{11} & a_{12} & \cdots & a_{1T} \ a_{21} & a_{22} & \cdots & a_{2T} \ \cdots & \cdots & \ddots & \cdots \ a_{k1} & a_{k2} & \cdots & a_{kT} \end{pmatrix} egin{pmatrix} Y_1 \ Y_2 \ dots \ Y_T \end{pmatrix} = egin{pmatrix} \sum_{i=1}^T a_{1i} Y_i \ \sum_{i=1}^T a_{2i} Y_i \ dots \ \sum_{i=1}^T a_{ki} Y_i \end{pmatrix}$$

por lo que cada elemento del vector $\hat{\beta}$ puede escribirse como:

$$\hat{\beta}_{j} = \sum_{i=1}^{T} a_{ji} Y_{i}$$

b) **Insesgados**

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{y}) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{X}\boldsymbol{\beta} + \mathbf{u}) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}$$

$$\hat{\boldsymbol{\beta}} = \boldsymbol{\beta} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}$$

$$E(\hat{\boldsymbol{\beta}}) = \boldsymbol{\beta}$$

Por tanto
$$E(\hat{\beta}_j) = \beta_j \ \forall j = 1,...,k$$

Matriz de varianzas y covarianzas del vector de estimadores:

$$\mathbf{V}(\hat{\boldsymbol{\beta}}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$$

- c) **ELIO**: estimadores lineales insesgados <u>óptimos</u>
- d) Eficientes

- > Propiedades asintóticas
- a) Insesgadez asintótica
- b) Consistencia

Condiciones suficientes de consistencia:

$$\lim_{T\to\infty} E(\hat{\boldsymbol{\beta}}) = \boldsymbol{\beta}$$

$$\lim_{T\to\infty}V(\hat{\boldsymbol{\beta}})=0$$

3.2.2.- PARÁMETRO DE DISPERSIÓN

ESTIMACIÓN

$$\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{T - k} = \frac{\hat{\mathbf{u}}'\hat{\mathbf{u}}}{T - k}$$

Objetivo que justifica esta expresión: obtener un estimador insesgado del parámetro de dispersión, teniendo en cuenta que

$$\frac{\hat{\mathbf{u}}'\hat{\mathbf{u}}}{\sigma^2} \sim \chi_{T-k}^2$$

$$E(\hat{\mathbf{u}}'\hat{\mathbf{u}}) = \sigma^2(T - k)$$

$$E(\hat{\sigma}^2) = \sigma^2$$

$$\hat{\boldsymbol{u}} = \boldsymbol{M}\boldsymbol{y}$$

$$\boldsymbol{M} = \boldsymbol{I}_T - \boldsymbol{X} (\boldsymbol{X}'\boldsymbol{X})^{\text{-}1} \boldsymbol{X}'$$

Propiedades de M: 1.Simétrica (M = M')

2. Idempotente ($\mathbf{MM} = \mathbf{M}$)

3.
$$r(\mathbf{M}) = tr(\mathbf{M}) = T - k$$

4.
$$MX = 0$$

$$\hat{\mathbf{u}} = \mathbf{M}\mathbf{u}$$

$$\hat{u}'\hat{u} = y'My = u'Mu$$

$$\hat{\sigma}^2 = \frac{\mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}}{T - k}$$

PROPIEDADES

- Para muestras finitas: sólo mantiene la insesgadez
- Asintóticas: asintóticamente insesgado y consistente.

$$\lim_{T\to\infty} E(\hat{\sigma}^2) = \sigma^2$$

$$\lim_{T\to\infty} \operatorname{var}(\hat{\sigma}^2) = 0$$

Obtención de la varianza

$$\frac{\mathbf{u'Mu}}{\sigma^2} \sim \chi_{T-k}^2$$

Resultado utilizado: distribuciones de formas cuadráticas (Trívez (2004), proposición 5, pag 121)

Si \mathbf{x} es un vector que se distribuye como una $N(\mathbf{0}, \mathbf{I})$ y A es una matriz simétrica e idempotente con rango y traza igual a $r \le T$, entonces:

$$\mathbf{x}'\mathbf{A}\mathbf{x} \sim \chi_r^2$$

Aplicación a nuestro caso: \mathbf{u} es el vector $N(\mathbf{0}, \sigma^2 \mathbf{I})$ y \mathbf{M} simétrica e idempotente:

$$\frac{\mathbf{u}'\mathbf{M}\mathbf{u}}{\sigma^2} \sim \chi_{T-k}^2$$

$$\operatorname{var}(\hat{\sigma}^2) = \frac{2\sigma^4}{T - k}$$

Estimación de $V(\hat{\beta})$:

$$\hat{V}(\hat{\beta}) = \hat{\sigma}^2 (\mathbf{X}'\mathbf{X})^{-1}$$

3.3.- ESTIMACIÓN MV DE LOS PARÁMETROS DEL MODELO. PROPIEDADES.

ESTIMACIÓN

$$\mathbf{y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$$

$$f(\mathbf{y}) = L(\mathbf{y}|\mathbf{\beta}, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{\frac{7}{2}}} \exp\left\{-\frac{1}{2\sigma^2}(\mathbf{y} - \mathbf{X}\mathbf{\beta})'(\mathbf{y} - \mathbf{X}\mathbf{\beta})\right\}$$

$$\ell = \ln L =$$

$$-\frac{T}{2}\ln(2\pi) - \frac{T}{2}\ln\sigma^2 - \frac{1}{2\sigma^2}(\mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'\mathbf{X}'\mathbf{y} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta})$$

$$\frac{\partial \ell}{\partial \boldsymbol{\beta}} = -\frac{1}{2\sigma^2} \left(-2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \right)$$

$$\frac{\partial \ell}{\partial \sigma^2} = -\frac{T}{2}\frac{1}{\sigma^2} + \frac{\left(\mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'\mathbf{X}'\mathbf{y} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \right)}{2\sigma^4} = \frac{\left(\mathbf{y}'\mathbf{y} - 2\boldsymbol{\beta}'\mathbf{X}'\mathbf{y} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \right) - T\sigma^2}{2\sigma^4}$$

Igualando a cero ambas derivadas:

$$\mathbf{X}'\mathbf{y} = \mathbf{X}'\mathbf{X}\tilde{\boldsymbol{\beta}}$$
$$\mathbf{y}'\mathbf{y} - 2\tilde{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} + \tilde{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\tilde{\boldsymbol{\beta}} = T\tilde{\boldsymbol{\sigma}}^{2}$$

Conclusión:

$$\tilde{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$$

$$\tilde{\sigma}^2 = \frac{\mathbf{y}'\mathbf{y} - 2\tilde{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} + \tilde{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\tilde{\boldsymbol{\beta}}}{T} = \frac{\hat{\mathbf{u}}'\hat{\mathbf{u}}}{T}$$

PROPIEDADES

> Muestras finitas

- Parámetros de posición: lineales, insesgados, óptimos y eficientes.
- Parámetro de dispersión: sesgado, no cumple ninguna propiedad en muestras pequeñas.

$$E(\tilde{\sigma}^2) = \frac{E(\hat{\mathbf{u}}'\hat{\mathbf{u}})}{T} = \frac{\sigma^2(T-k)}{T} \neq \sigma^2$$

> Asintóticas

- Parámetros de posición: asintóticamente insesgados y consistentes.
- Parámetro de dispersión: asintóticamente insesgado y consistente.

$$\lim_{T\to\infty} E(\tilde{\sigma}^2) = \sigma^2$$

$$\lim_{T\to\infty} \operatorname{var}(\tilde{\sigma}^2) = 0$$

$$E(\tilde{\sigma}^2) = \frac{(T-k)\sigma^2}{T}$$
$$var(\tilde{\sigma}^2) = \frac{2\sigma^4(T-k)}{T^2}$$

3.4.- ESTIMACIÓN POR INTERVALO

3.4.1.- PARÁMETROS DE POSICIÓN

$$\hat{\boldsymbol{\beta}} \sim N\left(\boldsymbol{\beta}, \sigma^{2} \left(\mathbf{X}'\mathbf{X}\right)^{-1}\right)$$

$$\hat{\boldsymbol{\beta}}_{j} \sim N\left(\boldsymbol{\beta}_{j}, \sigma^{2} \left(\mathbf{X}'\mathbf{X}\right)_{jj}^{-1}\right)$$

$$\frac{\hat{\boldsymbol{\beta}}_{j} - \boldsymbol{\beta}_{j}}{\sqrt{\sigma^{2} \left(\mathbf{X}'\mathbf{X}\right)_{jj}^{-1}}} \sim N(0,1)$$

$$\frac{\left(\hat{\beta}_{j} - \beta_{j}\right)}{\sqrt{\sigma^{2}\left(X'X'\right)_{jj}^{-1}}} \sim t_{T-k}$$

$$\sqrt{\frac{\left(T - k\right)\hat{\sigma}^{2}/\sigma^{2}}{\left(T - k\right)}} \sim t_{T-k}$$

Condición: independencia entre la N(0,1) y la χ_{T-k}^2 .

Por tanto:

$$\frac{\left(\hat{\beta}_{j}-\beta_{j}\right)}{\hat{\sigma}_{\hat{\beta}_{i}}} \sim t_{T-k}$$

$$\hat{oldsymbol{eta}}_{j}\pm t_{arepsilon/2}\hat{oldsymbol{\sigma}}_{\hat{eta}_{j}}$$

3.4.2.- PARÁMETRO DE DISPERSIÓN

$$\frac{\left(T-k\right)\hat{\sigma}^2}{\sigma^2} \sim \chi_{T-k}^2$$

$$\left[\frac{\left(T-k\right)\hat{\sigma}^2}{\chi^2_{\varepsilon/2}};\!\frac{\left(T-k\right)\hat{\sigma}^2}{\chi^2_{1-\varepsilon/2}}\right]$$

3.5.- EL MODELO LINEAL GENERAL EN DESVIACIONES

donde
$$x'_{di} = (x_{2i} \quad x_{3i} \quad \cdots \quad x_{ki}) \text{ y } \boldsymbol{\beta}^* = \begin{pmatrix} \boldsymbol{\beta}_2 \\ \vdots \\ \boldsymbol{\beta}_k \end{pmatrix}$$

$$\Leftarrow \begin{cases} \hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \dots + \hat{\beta}_k X_{ki} \\ \overline{Y} = \hat{\beta}_1 + \hat{\beta}_2 \overline{X}_2 + \dots + \hat{\beta}_k \overline{X}_k \end{cases}$$

$$\downarrow \downarrow$$

$$\hat{y}_i = \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki}$$

$$\hat{y}_i = x'_{di} \hat{\beta}^*$$

Expresión matricial:

$$\hat{\mathbf{y}}_d = \mathbf{X}_d \hat{\mathbf{\beta}}^*$$

$$\mathbf{y}_{d} = \begin{pmatrix} y_{1} \\ y_{2} \\ \vdots \\ y_{T} \end{pmatrix} \mathbf{X}_{d} = \begin{pmatrix} x_{21} & \cdots & x_{k1} \\ x_{22} & \cdots & x_{k2} \\ \vdots & \ddots & \vdots \\ x_{2T} & \cdots & x_{kT} \end{pmatrix} \mathbf{u} - \overline{\mathbf{u}} = \begin{pmatrix} u_{1} - \overline{u} \\ u_{2} - \overline{u} \\ \vdots \\ u_{T} - \overline{u} \end{pmatrix}$$

$$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \dots + \hat{\beta}_k X_{ki} + \hat{u}_i$$

$$\overline{Y} = \hat{\beta}_1 + \hat{\beta}_2 \overline{X}_2 + \dots + \hat{\beta}_k \overline{X}_k$$

$$y_i = \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki} + \hat{u}_i$$

$$y_i = \mathbf{x}'_{di}\hat{\boldsymbol{\beta}}^* + \hat{u}_i$$

$$\mathbf{y}_d = \mathbf{X}_d \hat{\boldsymbol{\beta}}^* + \hat{\mathbf{u}}$$

siendo
$$\hat{\mathbf{u}} = \begin{pmatrix} \hat{u}_1 \\ \hat{u}_2 \\ \vdots \\ \hat{u}_T \end{pmatrix}$$

$$\mathbf{S} = \hat{\mathbf{u}}'\hat{\mathbf{u}} = \left(\mathbf{y}_d - \mathbf{X}_d\hat{\boldsymbol{\beta}}^*\right)'\left(\mathbf{y}_d - \mathbf{X}_d\hat{\boldsymbol{\beta}}^*\right) = \mathbf{y}_d'\mathbf{y}_d - 2\hat{\boldsymbol{\beta}}^{*'}\mathbf{X}_d'\mathbf{y}_d + \hat{\boldsymbol{\beta}}^{*'}\mathbf{X}_d'\mathbf{X}_d\hat{\boldsymbol{\beta}}^*$$

$$\frac{\partial S}{\partial \hat{\beta}^*} = 0 \qquad \mathbf{X}_d' \mathbf{y}_d = \mathbf{X}_d' \mathbf{X}_d \hat{\beta}^*$$

$$\hat{\boldsymbol{\beta}}^* = (\mathbf{X}_d' \mathbf{X}_d)^{-1} \mathbf{X}_d' \mathbf{y}_d$$