

Unidad 4 Regresión Lineal Múltiple

La idea de la regresión lineal múltiple es modelar el valor esperado de la variable respuesta como combinación lineal de más de una variable explicativa. Si Y denota la variable respuesta y X_1, \dots, X_p las variables explicativas, entonces el primer supuesto del modelo de regresión lineal múltiple es

$$E(Y|X_1 = x_1, \dots, X_p = x_p) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p$$

El supuesto de varianza constante se mantiene

$$V(Y|X_1 = x_1, \dots, X_p = x_p) = \sigma^2$$

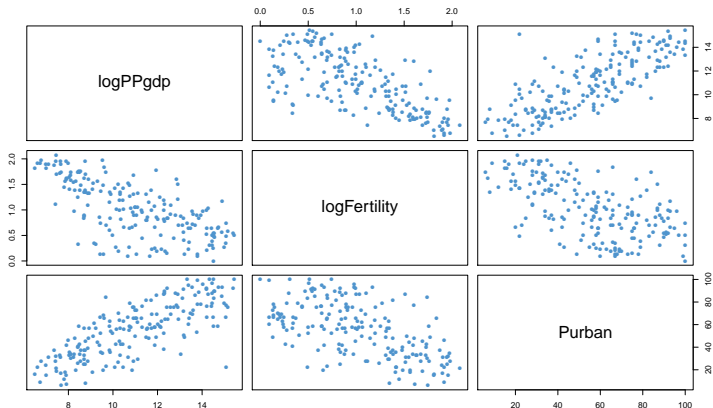
Las solución al problema de inferencia de este modelo (estimación puntual, por intervalos y pruebas de hipótesis) es relativamente *fácil*.

La principal dificultad del análisis de RLM es la interpretación del modelo. Incrementar el número de variables repercute en lo siguiente:

- Entender la relación entre las X y Y , porque ya no es posible graficar.
- La interpretación de los parámetros.
- Hacer inferencias simultáneas.
- Interacción entre las variables.
- Selección del *mejor* modelo.
- Identificar desviaciones de los supuestos.



Ejemplo

Se tiene un conjunto de datos con observaciones de 193 países de la ONU. De cada país se registraron tres variables: tasa de fecundidad (`fecundidad`), producto interno bruto per capita (`pibp`) y porcentaje de población en áreas urbanas (`purbana`). El objetivo es modelar la fecundidad a partir de las otras dos variables.



Ejemplo (cont.)

Como la relación entre $\log(\text{fecundidad})$ y $\log(\text{pibpc})$ y entre $\log(\text{fecundidad})$ y purbana parece ser lineal, podemos ajustar un modelo RLS en cada caso.



Ejemplo (cont.)

- El coeficiente R^2 del modelo que relaciona $\log(\text{fecundidad})$ y $\log(\text{pibpc})$ es 0.4591. Esto significa que $\log(\text{pibpc})$ explica 46% de la variabilidad de $\log(\text{fecundidad})$.
- En el modelo de $\log(\text{fecundidad})$ contra purbana el valor del R^2 es 0.3482.
- ¿Cuál será el valor del R^2 en un modelo que combine las dos variables explicativas? ¿Será la suma de los R^2 de los modelos individuales?
- En el gráfico de dispersión de $\log(\text{pibpc})$ y purbana se aprecia alguna relación entre estas dos variables. Posiblemente, parte de la variabilidad de $\log(\text{fecundidad})$ que explican $\log(\text{pibpc})$ y purbana sea *común*.
- El valor del R^2 en el modelo con las dos variables es 0.4689.

Planteamiento del Problema

El objetivo es modelar Y a partir de p variables explicativas X_1, \dots, X_p . Al igual que en el modelo RLS se asume que el valor esperado de Y se puede expresar como función lineal de las X_i :

$$E(Y|X_1 = x_1, \dots, X_p = x_p) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p$$

Se asume que Y varía alrededor de su media de manera independiente de las X_i :

$$V(Y|X_1 = x_1, \dots, X_p = x_p) = \sigma^2$$

Lo anterior se puede representar como

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p + \epsilon$$

donde $\epsilon \sim (0, \sigma^2)$.

Planteamiento (cont.)

El modelo tiene $p + 2$ parámetros desconocidos a estimar. Para ello se asume que se tienen n observaciones de la variable respuesta con sus respectivas variables explicativas.

$$Y_1 = \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} + \dots + \beta_p x_{1p} + \epsilon_1$$

$$Y_2 = \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} + \dots + \beta_p x_{2p} + \epsilon_2$$

$$\vdots$$

$$Y_n = \beta_0 + \beta_1 x_{n1} + \beta_2 x_{n2} + \dots + \beta_p x_{np} + \epsilon_n$$

Además se asume que los errores no están correlacionados, es decir, $Cov(\epsilon_i, \epsilon_j) = 0$, con $i, j = 1, \dots, n$, y $i \neq j$.

Planteamiento (cont.)

Para facilitar la resolución del problema se utilizar la siguiente representación matricial:

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1k} \\ 1 & x_{21} & x_{22} & \cdots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nk} \end{pmatrix} \quad \boldsymbol{\epsilon} = \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{pmatrix} \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix}$$

Con lo cual el modelo queda expresado como

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}.$$

con $\boldsymbol{\epsilon} \sim (\mathbf{0}_n, \sigma^2 \mathbf{I}_n)$. La matriz \mathbf{X} recibe el nombre de matriz de diseño.

Al igual que en el caso *simple*, dado un valor específico de β , se define el vector de valores ajustados como $\hat{\mathbf{y}} = \mathbf{X}\hat{\beta}$ y el vector de errores como $\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}}$. Entonces, la función suma de cuadrados de los errores se define como

$$Q(\beta) = \mathbf{e}'\mathbf{e} = (\mathbf{y} - \mathbf{X}\beta)'(\mathbf{y} - \mathbf{X}\beta)$$

El estimador de MCO de β es el vector $\hat{\beta}$ tal que $Q(\hat{\beta})$ es mínima.

Primero se debe notar que

$$Q(\beta) = \mathbf{y}'\mathbf{y} - 2\mathbf{y}'\mathbf{X}\beta + \beta'\mathbf{X}'\mathbf{X}\beta$$

Entonces:

$$\nabla Q(\beta) = -2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\beta = 0 \quad \Rightarrow \quad \mathbf{X}'\mathbf{X}\beta = \mathbf{X}'\mathbf{y}.$$

Las ecuaciones del sistema (expresado en forma matricial)

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

reciben el nombre de ecuaciones normales. Si la matriz de diseño \mathbf{X} es de rango completo (por columnas), entonces $\mathbf{X}'\mathbf{X}$ es de rango completo y por lo tanto, invertible. Entonces, la solución al sistema de ecuaciones normales es

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

Estimación por MCO (cont.)

Para verificar que $Q(\beta)$ tiene un mínimo en $\hat{\beta}$ utilizamos el criterio de las segundas derivadas parciales. Es sencillo mostrar que

$$H_Q(\beta) = 2\mathbf{X}'\mathbf{X}$$

que no depende de β . Si \mathbf{v} es un vector de dimensión $p + 1$ diferente de $\mathbf{0}$, y definimos $\mathbf{u} = \mathbf{X}\mathbf{v}$, entonces

$$\mathbf{v}'\mathbf{X}'\mathbf{X}\mathbf{v} = (\mathbf{X}\mathbf{v})'\mathbf{X}\mathbf{v} = \mathbf{u}'\mathbf{u}$$

Como asumimos que \mathbf{X} es de rango completo (por columnas), $\mathbf{X}\mathbf{v} \neq \mathbf{0}$. Luego, $\mathbf{X}'\mathbf{X}$ es positiva definida.

Por lo tanto, $\hat{\beta}$ es el estimador de MCO del modelo RLM.

Teorema de Gauss-Markov

En el modelo RLM $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e}$, bajo las hipótesis:

- $\boldsymbol{\epsilon} \sim (\mathbf{0}, \sigma^2\mathbf{I})$.
- \mathbf{X} de rango completo.

el estimador de MCO de $\boldsymbol{\beta}$ es el MELI (BLUE). Es decir, $\hat{\boldsymbol{\beta}}$ es insesgado para $\boldsymbol{\beta}$ y si $\tilde{\boldsymbol{\beta}}$ es otro estimador de insesgado de $\boldsymbol{\beta}$ y \mathbf{v} es un vector de dimensión $p + 1$ distinto de $\mathbf{0}$, entonces $\mathbf{v}'V(\tilde{\boldsymbol{\beta}})\mathbf{v} \geq \mathbf{v}'V(\hat{\boldsymbol{\beta}})\mathbf{v}$.

Como $\epsilon \sim (\mathbf{0}, \sigma^2 \mathbf{I})$ se sigue que $\mathbf{Y} \sim (\mathbf{X}\beta, \sigma^2 \mathbf{I})$. Luego,

$$\begin{aligned} E(\hat{\beta}) &= E\left((\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}\right) \\ &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' E(\mathbf{Y}) \\ &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{X}\beta \\ &= \beta. \end{aligned}$$

Entonces, $\hat{\beta}$ es insesgado para β .

$$\begin{aligned} V(\hat{\beta}) &= V\left((\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}\right) \\ &= \left((\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\right) V(\mathbf{Y}) \left((\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\right)' \\ &= \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{X}' (\mathbf{X}'\mathbf{X})^{-1} \\ &= \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \end{aligned}$$

TGM: demostración

Sea $\tilde{\beta}$ otro estimador lineal insesgado para β . Es decir, existe una matrix $\mathbf{A}_{(p+1) \times n}$ tal que $\tilde{\beta} = \mathbf{A}\mathbf{Y}$. Como se pide que $\tilde{\beta}$ sea insesgado para β se debe cumplir

$$\begin{aligned} E(\tilde{\beta}) &= E(\mathbf{A}\mathbf{Y}) \\ &= \mathbf{A}E(\mathbf{Y}) \\ &= \mathbf{A}\mathbf{X}\beta. \end{aligned}$$

Lo anterior implica que $\mathbf{A}\mathbf{X} = \mathbf{I}_{p+1}$. Ahora sea $\mathbf{C}_{(p+1) \times n}$ tal que $\mathbf{A} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' + \mathbf{C}$. Es fácil verificar que $\mathbf{C}\mathbf{X} = \mathbf{0}$. Ahora calculamos la varianza de $\tilde{\beta}$.

$$\begin{aligned} V(\tilde{\beta}) &= V(\mathbf{A}\mathbf{Y}) \\ &= \mathbf{A}V(\mathbf{Y})\mathbf{A}' \\ &= \sigma^2 \left((\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' + \mathbf{C} \right) \left((\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' + \mathbf{C} \right)' \\ &= \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} + \sigma^2 \mathbf{C}\mathbf{C}' \\ &= V(\hat{\beta}) + \sigma^2 \mathbf{C}\mathbf{C}'. \end{aligned}$$

Sea \mathbf{v} un vector de dimensión $p + 1$ y $\mathbf{u} = \mathbf{C}'\mathbf{v}$, entonces $\mathbf{v}'\mathbf{C}\mathbf{C}'\mathbf{v} = (\mathbf{C}'\mathbf{v})' \mathbf{C}'\mathbf{v} = \mathbf{u}'\mathbf{u} \geq 0$. Entonces,

$$\mathbf{v}'V(\tilde{\beta})\mathbf{v} = \mathbf{v}'V(\hat{\beta})\mathbf{v} + \sigma^2\mathbf{v}'\mathbf{C}\mathbf{C}'\mathbf{v} \geq \mathbf{v}'V(\hat{\beta})\mathbf{v}.$$

Por lo tanto, el estimador de MCO de β es el MELI.

Valores ajustados, residuos y suma de cuadrados residual

El vector de valores ajustados se define como

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

La matriz $\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ se conoce como matriz *sombrero* (*hat*) y se denota por \mathbf{H} . El nombre se debe a que \mathbf{H} le pone el sombrero a \mathbf{y} . Se puede mostrar que \mathbf{H} es simétrica e idempotente. El vector de residuos entonces es

$$\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - \mathbf{H}\mathbf{y} = (\mathbf{I} - \mathbf{H})\mathbf{y}$$

Como \mathbf{H} es simétrica e idempotente, $\mathbf{I} - \mathbf{H}$ también lo es. Entonces, la suma de cuadrados residual se calcula como

$$SC_{error} = \mathbf{e}'\mathbf{e} = \mathbf{y}'(\mathbf{I} - \mathbf{H})'(\mathbf{I} - \mathbf{H})\mathbf{y} = \mathbf{y}'(\mathbf{I} - \mathbf{H})\mathbf{y}$$

Otra expresión útil y que se demuestra fácilmente es la siguiente

$$SC_{error} = \mathbf{y}'\mathbf{y} - \hat{\mathbf{y}}'\hat{\mathbf{y}}.$$

Estimación por Máxima Verosimilitud

Para hacer estimación por intervalos y pruebas de hipótesis debemos agregar el supuesto de normalidad multivariada en los errores

$$\epsilon \sim N_n(\mathbf{0}_n, \sigma^2 \mathbf{I}_n) \quad \Rightarrow \quad \mathbf{Y} \sim N_n(\mathbf{X}\beta, \sigma^2 \mathbf{I}_n)$$

Recordemos que en el caso general si $\mathbf{Y} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ la densidad de \mathbf{Y} está dada por

$$f(\mathbf{y}) = (2\pi)^{-p/2} |\boldsymbol{\Sigma}|^{-1/2} \exp \left\{ -\frac{1}{2} (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu}) \right\}$$

Entonces, la verosimilitud de \mathbf{Y} en el modelo RLM es

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

$$\ell(\beta, \sigma^2 | \mathbf{y}, \mathbf{X}) = \log L(\cdot) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\beta)' (\mathbf{y} - \mathbf{X}\beta)$$

Estimación por Máxima Verosimilitud

Debemos maximizar $\ell(\boldsymbol{\beta}, \sigma^2 | \mathbf{y}, \mathbf{X})$ con respecto a $\boldsymbol{\beta}$ y σ^2 . Primero derivamos para encontrar los puntos críticos

$$\begin{aligned}\frac{\partial}{\partial \boldsymbol{\beta}} \ell &= -\frac{1}{\sigma^2} (\mathbf{X}'\mathbf{X}\boldsymbol{\beta} - \mathbf{X}'\mathbf{y}) \\ \frac{\partial}{\partial \sigma^2} \ell &= -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})\end{aligned}$$

Entonces

$$\begin{aligned}\frac{\partial}{\partial \boldsymbol{\beta}} \ell = 0 &\Rightarrow \mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{X}'\mathbf{y} \\ \frac{\partial}{\partial \sigma^2} \ell = 0 &\Rightarrow \sigma^2 = \frac{1}{n} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})' (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})\end{aligned}$$

La solución para σ^2 depende de $\boldsymbol{\beta}$ y la solución para $\boldsymbol{\beta}$ es la misma que por MCO. Entonces, si \mathbf{X} es de rango completo, los EMV son

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} \quad \text{y} \quad \hat{\sigma}^2 = \frac{1}{n} (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})' (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}).$$

Propiedades de los EMV

Como el EMV de β coincide con el EMCO, se sigue que

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

Además, por el supuesto de normalidad, se sigue que

$$\hat{\beta} \sim N_{p+1}(\beta, \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}).$$

Para determinar las propiedades de $\hat{\sigma}^2$ es necesario presentar algunos resultados adicionales sobre distribuciones de formas cuadráticas, aunque debemos notar que

$$\begin{aligned}\hat{\sigma}^2 &= \frac{1}{n} (\mathbf{y} - \mathbf{X}\hat{\beta})' (\mathbf{y} - \mathbf{X}\hat{\beta}) \\ &= \frac{1}{n} SC_{error} = \frac{1}{n} \\ &= \frac{1}{n} \mathbf{e}'\mathbf{e} \\ &= \frac{1}{n} \mathbf{y}' (\mathbf{I} - \mathbf{H}) \mathbf{y}.\end{aligned}$$

Distribución χ^2 no central

Definición (distribución χ^2 no central)

Se dice que una variable aleatoria (absolutamente) continua Y tiene una distribución χ^2 no central con parámetros ν y λ si su densidad está dada por

$$f(y|\nu, \lambda) = \sum_{j=0}^{\infty} Po(j|\lambda/2) \chi^2(y|\nu + 2j)$$

donde $Po(\cdot|\lambda/2)$ denota la densidad Poisson con parámetro $\lambda/2$ y $\chi^2(\cdot|\nu + 2j)$ denota la densidad χ^2 (central) con $\nu + j$ grados de libertad.

Lo anterior se denota como $Y \sim \chi^{*2}(\nu, \lambda)$, ν son grados de libertad y λ se conoce como parámetro de no centralidad.

Cuando $\lambda = 0$, la distribución χ^{*2} se reduce a la distribución χ^2 (central) con los mismos grados de libertad.

Resultados

Sean $\mathbf{Y} \sim N_k(\boldsymbol{\mu}, \mathbf{I})$, $\mathbf{A}_{k \times k}$, $\mathbf{B}_{k \times k}$ idempotentes de rango $r_1, r_2 \leq k$, respectivamente, y $\mathbf{C}_{l \times k}$ de rango completo, entonces:

- $\mathbf{Y}'\mathbf{A}\mathbf{Y} \sim \chi^{*2}(r, \boldsymbol{\mu}'\mathbf{A}\boldsymbol{\mu})$.
- $\mathbf{Y}'\mathbf{A}\mathbf{Y} \perp \mathbf{Y}'\mathbf{B}\mathbf{Y}$ si y sólo si $\mathbf{A}\mathbf{B} = \mathbf{0}$.
- $\mathbf{Y}'\mathbf{A}\mathbf{Y} \perp \mathbf{C}\mathbf{Y}$ si y sólo si $\mathbf{C}\mathbf{A} = \mathbf{0}$.

Propiedades de los EMV

Como $\hat{\sigma}^2 = \frac{1}{n} \mathbf{Y}' (\mathbf{I} - \mathbf{H}) \mathbf{Y}$, $\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$ y $\mathbf{I} - \mathbf{H}$ es idempotente de rango $n - p - 1$, se sigue que

$$\frac{n\hat{\sigma}^2}{\sigma^2} \sim \chi^{*2}(n - p - 1, \lambda)$$

donde

$$\begin{aligned}\lambda &= (\mathbf{X}\boldsymbol{\beta})' (\mathbf{I} - \mathbf{H}) \mathbf{X}\boldsymbol{\beta} \\ &= \boldsymbol{\beta}' \mathbf{X}' (\mathbf{I} - \mathbf{H}) \mathbf{X}\boldsymbol{\beta} \\ &= \boldsymbol{\beta}' (\mathbf{X}' \mathbf{X} - \mathbf{X}' \mathbf{H} \mathbf{X}) \boldsymbol{\beta} \\ &= 0.\end{aligned}$$

Por lo tanto,

$$\frac{n\hat{\sigma}^2}{\sigma^2} \sim \chi^2(n - p - 1)$$

De lo anterior se sigue que

$$E(\hat{\sigma}^2) = \frac{n-p-1}{n}\sigma^2$$
$$V(\hat{\sigma}^2) = 2\frac{n-p-1}{n^2}\sigma^4.$$

El EMV de σ^2 es sesgado pero es fácil mostrar que el EMCO es insesgado. Como $\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$, $(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ es de rango completo y

$$\begin{aligned}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{I} - \mathbf{H}) &= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' - (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' \\ &= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' - (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' \\ &= 0.\end{aligned}$$

Se sigue que $\hat{\beta} \perp SC_{error}$, por lo que $\hat{\beta} \perp \hat{\sigma}_{MCO}^2, \hat{\sigma}_{MV}^2$.

Debido a que

$$\frac{(n - p - 1) \hat{\sigma}_{MCO}^2}{\sigma^2} = \frac{SC_{error}}{\sigma^2} \sim \chi_{n-p-1}^2$$

es sencillo hacer inferencias sobre σ^2 .

Por ejemplo, un intervalo de confianza $100(1 - \alpha)\%$ para está dado por

$$\left(\frac{SC_{error}}{\chi_{n-p-1}^2(\alpha/2)}, \frac{SC_{error}}{\chi_{n-p-1}^2(1 - \alpha/2)} \right)$$

donde $\chi_{n-p-1}^2(\alpha/2)$ denota el cuantil superior $\alpha/2$ de una distribución χ_{n-p-1}^2

El intervalo anterior es sólo uno de los múltiples que se pueden construir. Cualquier par de cuantiles $\chi_{n-p-1}^2(1 - \alpha_1)$ y $\chi_{n-p-1}^2(\alpha_2)$ tales que $\alpha_1 + \alpha_2 = \alpha$ y $\alpha_1, \alpha_2 \geq 0$ se pueden utilizar para un intervalo de confianza $100(1 - \alpha)\%$. La principal diferencia está en la longitud de los intervalos calculados.

Inferencias para σ^2

Para contrastar las hipótesis

$$H_0 : \sigma^2 = \sigma_0^2 \quad \text{vs.} \quad H_1 : \sigma^2 \neq 0$$

con $\sigma_0^2 > 0$ fijo y conocido, se utiliza el estadístico

$$S = \frac{SC_{error}}{\sigma_0^2}$$

y la regla de decisión es *rechazar* H_0 si

$$S < \chi_{n-p-1}^2(1 - \alpha/2) \quad \text{o} \quad S > \chi_{n-p-1}^2(\alpha/2).$$

En la siguiente tabla se resumen los resultados para las pruebas de una cola

Hipótesis	Regla de rechazo
$H_0 : \sigma^2 \leq \sigma_0^2$ vs. $H_1 : \sigma^2 > \sigma_0^2$	$S > \chi_{n-p-1}^2(\alpha)$
$H_0 : \sigma^2 \geq \sigma_0^2$ vs. $H_1 : \sigma^2 < \sigma_0^2$	$S > \chi_{n-p-1}^2(1 - \alpha)$

Inferencias para β

Como β es un vector, se pueden construir *regiones de confianza* para el vector completo o intervalos de confianza para c.l. de su componentes.

Definición (región de confianza)

Sea una muestra aleatoria $\mathbf{Y}_1, \dots, \mathbf{Y}_n$ de una distribución $F(\mathbf{y}|\theta)$. Una región de confianza $100(1 - \alpha)\%$ para θ es un conjunto aleatorio $C = C(\mathbf{Y}_1, \dots, \mathbf{Y}_n)$ tal que

$$P(C \ni \theta) \geq 1 - \alpha.$$

Dada una región de confianza para θ , se puede construir una prueba de hipótesis para contrastar

$$H_0 : \theta = \theta_0 \quad \text{vs.} \quad H_1 : \theta \neq \theta_0$$

para algún vector de constantes conocidas θ_0 con regla de decisión *rechazar* H_0 si

$$\theta_0 \notin C$$

con una significancia α .

Sabemos que $\hat{\beta} \sim N_{p+1}(\beta, \sigma^2 (\mathbf{X}'\mathbf{X})^{-1})$, entonces es fácil mostrar que

$$(\hat{\beta} - \beta)' \mathbf{X}'\mathbf{X} (\hat{\beta} - \beta) / \sigma^2 \sim \chi_{p+1}^2.$$

Además, como $(n - p - 1)\hat{\sigma}_{MCO}^2 / \sigma^2 \sim \chi_{n-p-1}^2$ y $\hat{\beta} \perp \hat{\sigma}_{MCO}^2$, se sigue que

$$\frac{(\hat{\beta} - \beta)' \mathbf{X}'\mathbf{X} (\hat{\beta} - \beta)}{\hat{\sigma}_{MCO}^2 (p + 1)} \sim F_{p+1, n-p-1}.$$

Por lo tanto, una región de confianza $100(1 - \alpha)\%$ para β está dada por

$$C = \left\{ \beta \in \mathbb{R}^{p+1} \mid (\hat{\beta} - \beta)' \mathbf{X}'\mathbf{X} (\hat{\beta} - \beta) \leq \hat{\sigma}_{MCO}^2 (p+1) F_{p+1, n-p-1}(\alpha) \right\}.$$

Una prueba de hipótesis para contrastar

$$H_0 : \beta = \beta_0 \quad \text{vs.} \quad H_1 : \beta \neq \beta_0$$

consiste en rechazar H_0 con una significancia α si

$$\beta_0 \notin C \Leftrightarrow (\hat{\beta} - \beta_0)' \mathbf{X}'\mathbf{X} (\hat{\beta} - \beta_0) > \hat{\sigma}_{MCO}^2 (p+1) F_{p+1, n-p-1}(\alpha)$$

donde $F_{p+1, n-p-1}(\alpha)$ denota el cuantil superior α de una distribución $F_{p+1, n-p-1}$.

Inferencias para β

Otra posibilidad es hacer inferencias sobre c.l. de las componentes de β del tipo $\mathbf{a}'\beta$, con \mathbf{a} un vector de dimensión $p + 1$ de constantes conocidas.

Por las propiedades de las distribución NMV

$$\mathbf{a}'\hat{\beta} \sim N_1 \left(\mathbf{a}'\beta, \sigma^2 \mathbf{a}' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{a} \right)$$

Entonces,

$$\frac{\mathbf{a}' (\hat{\beta} - \beta)}{\sigma \sqrt{\mathbf{a}' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{a}}} \sim N(0, 1)$$

Si *reemplazamos* σ^2 por $\hat{\sigma}_{MCO}^2$, entonces

$$T_{\mathbf{a}} = \frac{\mathbf{a}' (\hat{\beta} - \beta)}{\hat{\sigma}_{MCO} \sqrt{\mathbf{a}' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{a}}} \sim t_{n-p-1}.$$

El estadístico $T_{\mathbf{a}}$ se puede utilizar para construir intervalos de confianza y pruebas de hipótesis para $\mathbf{a}'\beta$.

Inferencias para β

Un intervalo de confianza $100(1 - \alpha)\%$ para $\mathbf{a}'\beta$ esta dado por

$$\mathbf{a}'\hat{\beta} \pm t_{n-p-a}(\alpha/2)\hat{\sigma}_{MCO}\sqrt{\mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}}$$

donde $t_{n-p-a}(\alpha/2)$ denota el cuantil superior $\alpha/2$ de una distribución t_{n-p-a} . Las pruebas de hipótesis se resumen en el siguiente cuadro

Hipótesis	Regla de rechazo
$H_0 : \mathbf{a}'\beta = b$ vs. $H_1 : \mathbf{a}'\beta \neq b$	$ T_{\mathbf{a}} > t_{n-p-a}(\alpha/2)$
$H_0 : \mathbf{a}'\beta \geq b$ vs. $H_1 : \mathbf{a}'\beta < b$	$T_{\mathbf{a}} < -t_{n-p-a}(\alpha)$
$H_0 : \mathbf{a}'\beta \leq b$ vs. $H_1 : \mathbf{a}'\beta > b$	$T_{\mathbf{a}} > t_{n-p-a}(\alpha)$

donde

$$T_{\mathbf{a}} = \frac{\mathbf{a}'\hat{\beta} - b}{\hat{\sigma}_{MCO}\sqrt{\mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}}}$$

y b es una constante conocida

Inferencias para β

Como casos particulares, cuando es de la forma $\mathbf{a} = \mathbf{1}_{(i+1)}$, entonces $\mathbf{a}'\beta = \beta_i$, para $i = 0, \dots, p$.

Un intervalo de confianza $100(1 - \alpha)\%$ para β_i esta dado por

$$\hat{\beta}_i \pm t_{n-p-a}(\alpha/2) \hat{\sigma}_{MCO} \sqrt{(\mathbf{X}'\mathbf{X})_{ii}^{-1}}$$

donde $\hat{\beta}_i$ es la i -ésima entrada de $\hat{\beta}$ y $(\mathbf{X}'\mathbf{X})_{ii}^{-1}$ es el i -ésimo elemento de la diagonal de $(\mathbf{X}'\mathbf{X})^{-1}$. Las pruebas de hipótesis para β_i se resumen en el siguiente cuadro

Hipótesis	Regla de rechazo
$H_0 : \beta_i = b$ vs. $H_1 : \beta_i \neq b$	$ t > t_{n-p-a}(\alpha/2)$
$H_0 : \beta_i \geq b$ vs. $H_1 : \beta_i < b$	$t < -t_{n-p-a}(\alpha)$
$H_0 : \beta_i \leq b$ vs. $H_1 : \beta_i > b$	$t > t_{n-p-a}(\alpha)$

donde

$$t = \frac{\hat{\beta}_i}{\hat{\sigma}_{MCO} \sqrt{(\mathbf{X}'\mathbf{X})_{ii}^{-1}}}$$

y b es una constante conocida.

Intervalos de confianza y predicción

Otro caso particular son los intervalos de confianza para la respuesta media y los intervalos de predicción.

Supongamos que $\mathbf{x}^* = (x_1^*, \dots, x_p^*)'$ es un vector de constantes fijas y conocidas, un estimador del valor esperado de Y dado $\mathbf{X} = \mathbf{x}^*$ es $\mathbf{x}_0' \hat{\beta}$, con $\mathbf{x}_0 = (1, \mathbf{x}^*)'$.

Un intervalo de confianza $100(1 - \alpha)\%$ para $E(Y|\mathbf{x}^*)$ está dado por

$$\mathbf{x}_0' \hat{\beta} \pm t_{n-p-a}(\alpha/2) \hat{\sigma}_{MCO} \sqrt{\mathbf{x}_0' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0}.$$

También es posible hacer pruebas de hipótesis sobre $E(Y|\mathbf{x}^*)$, basta adecuar las reglas de decisión anteriores. Un intervalo de predicción $100(1 - \alpha)\%$ para una nueva observación de Y dado $\mathbf{X} = \mathbf{x}^*$ está dado por

$$\mathbf{x}_0' \hat{\beta} \pm t_{n-p-a}(\alpha/2) \hat{\sigma}_{MCO} \sqrt{1 + \mathbf{x}_0' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0}.$$

La justificación de este resultado es similar al caso del modelo RLS.

Intervalos de confianza simultáneos para $\mathbf{a}'\beta$

Si \mathbf{a}' es un vector de dimensión $p + 1$, sabemos que

$$T_{\mathbf{a}} = \frac{\mathbf{a}'(\hat{\beta} - \beta)}{\hat{\sigma}_{MCO} \sqrt{\mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}}} \sim t_{n-p-1}.$$

o equivalentemente

$$T_{\mathbf{a}}^2 = \frac{\mathbf{a}'(\hat{\beta} - \beta)'(\hat{\beta} - \beta)\mathbf{a}}{\hat{\sigma}_{MCO}^2 \mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}} \sim F_{1, n-p-1}.$$

Es sencillo mostrar que

$$\max_{\mathbf{a} \in \mathbb{R}^{p+1}} (p+1)^{-1} T_{\mathbf{a}}^2 = \frac{(\hat{\beta} - \beta)' \mathbf{X}'\mathbf{X} (\hat{\beta} - \beta)}{(p+1)\hat{\sigma}_{MCO}^2} \sim F_{p+1, n-p-1}.$$

* El resultado anterior se usó para construir regiones de confianza para β .

Intervalos de confianza simultáneos para $\mathbf{a}'\boldsymbol{\beta}$

Por lo tanto, para todo $\mathbf{a} \in \mathbb{R}^{p+1}$ se cumple

$$P(T_{\mathbf{a}}^2 \leq K_{\alpha}) \geq 1 - \alpha$$

con $K_{\alpha} = (p+1)F_{p+1, n-p-1}(\alpha)$. O equivalentemente

$$P\left(-\sqrt{K_{\alpha}} \leq \frac{\mathbf{a}'(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})}{\hat{\sigma}_{MCO}\sqrt{\mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}}} \leq \sqrt{K_{\alpha}}\right) \geq 1 - \alpha$$

De donde se obtiene un intervalo de confianza $100(1 - \alpha)\%$ para $\mathbf{a}'\boldsymbol{\beta}$ simultáneo para todo $\mathbf{a} \in \mathbb{R}^{p+1}$

$$\mathbf{a}'\boldsymbol{\beta} \in \mathbf{a}'\hat{\boldsymbol{\beta}} \pm \hat{\sigma}_{MCO}\sqrt{K_{\alpha}\mathbf{a}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{a}}.$$