

Teorema N4: Sea $\mathbf{X}' = (X_1, \dots, X_k)$ un vector k -dimensional con distribución normal multivariada, luego la distribución marginal de cualquier subconjunto de componentes tiene distribución normal multivariada. En particular cada componente es normal.

Demostración: Sea $\mathbf{X}^* = (X_{k_1}, \dots, X_{k_h})$, $k_1 < k_2 < \dots < k_h$, luego se tiene que $\mathbf{X}^* = \mathbf{A}\mathbf{X}$, donde \mathbf{A} es la matriz de $h \times k$ dada por:

$$a_{ij} = \begin{cases} 1 & \text{si } j = k_i \\ 0 & \text{si } j \neq k_i \end{cases}$$

$$1 \leq i \leq h, 1 \leq j \leq k.$$

Es fácil ver que \mathbf{A} es una matriz de rango h .

Teorema N5: Si \mathbf{X} es un vector k -dimensional con distribución $N_k(\boldsymbol{\mu}, \mathbf{Q})$, luego

$$(\mathbf{X} - \boldsymbol{\mu})' \mathbf{Q}^{-1} (\mathbf{X} - \boldsymbol{\mu}) \sim \chi_k^2$$

Demostración: Por lo ya visto, resulta que $\mathbf{X} = \mathbf{B}\mathbf{Y} + \boldsymbol{\mu}$ donde \mathbf{Y} es $N(\mathbf{0}_k, \mathbf{I}_k)$

$$\mathbf{Y} = \mathbf{B}^{-1}(\mathbf{X} - \boldsymbol{\mu})$$

y además

$$\mathbf{B}\mathbf{B}' = \mathbf{Q}$$

Luego

$$\mathbf{Y}\mathbf{Y}' = (\mathbf{X} - \boldsymbol{\mu})' \mathbf{B}'^{-1} \mathbf{B}^{-1} (\mathbf{X} - \boldsymbol{\mu}) = (\mathbf{X} - \boldsymbol{\mu})' \mathbf{Q}^{-1} (\mathbf{X} - \boldsymbol{\mu})$$

El teorema resulta del hecho que

$$\mathbf{Y}'\mathbf{Y} = \sum_{i=1}^k Y_i^2$$

tiene distribución χ_k^2 , ya que las Y_i son variables aleatorias independientes con distribución $N(0, 1)$.

Teorema N6: Si \mathbf{X} es un vector k -dimensional con distribución $N_k(\boldsymbol{\mu}, \sigma^2 \mathbf{I}_k)$ y \mathbf{P} una matriz simétrica e idempotente de rango r , entonces

$$\frac{(\mathbf{X} - \boldsymbol{\mu})' \mathbf{P} (\mathbf{X} - \boldsymbol{\mu})}{\sigma^2} \sim \chi_r^2$$

Tests y Regiones de Confianza

Hasta ahora hemos trabajado sólo con las hipótesis Ω . Sin embargo para deducir tests y regiones de confianza con nivel exacto será necesario que hagamos un supuesto adicional: **normalidad conjunta de los errores**

Supondremos que las y_i 's se distribuyen conjuntamente según una normal multivariada.

Podremos deducir:

- intervalos de confianza de nivel exacto para funciones paramétricas estimables
- tests de nivel exacto para hipótesis que involucran a los parámetros
- conjuntos o regiones de confianza para la estimación simultánea de más de una función paramétrica estimable.

Nuestro nuevo modelo será:

$$\Omega: \mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I}) \quad \text{rg}(\mathbf{X}) = r \quad \boldsymbol{\beta} \in \mathfrak{R}^p$$

Observemos que en este caso suponer que $\Sigma_{\mathbf{Y}} = \sigma^2\mathbf{I}$ es equivalente a asumir que las y_i , $1 \leq i \leq n$, son independientes.




Figure 6.1 from Fox (1997)

Bajo estas condiciones se obtiene el siguiente resultado:

Teorema: Supongamos que se tiene el modelo

$$\Omega: \mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I}) \quad \text{rg}(\mathbf{X}) = p \quad \boldsymbol{\beta} \in \mathfrak{R}^p.$$

Luego, $\hat{\boldsymbol{\beta}}$ y s^2 son funciones de estadísticos suficientes y completos y por lo tanto, $\hat{\boldsymbol{\beta}}$ y s^2 son estimadores IMVU de $\boldsymbol{\beta}$ y σ^2 , respectivamente.

Si nuestro modelo es

$$E(\mathbf{Y}) = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_px_p$$

podríamos tener interés en testear hipótesis como las que siguen:

$$H_o: \beta_j = 0 \quad \text{vs.} \quad H_1: \beta_j \neq 0$$

$$H_o: \beta_1 - \beta_2 = 0 \quad \text{vs.} \quad H_1: \beta_1 - \beta_2 \neq 0$$

$$H_o: \beta_1 = \beta_2 = \dots = \beta_p = 0 \quad \text{vs.} \quad H_1: \text{existe } j: \beta_j \neq 0$$

Todas estas hipótesis son de la forma $\mathbf{c}'\boldsymbol{\beta} = 0$ o $\mathbf{c}\boldsymbol{\beta} = \mathbf{0}$.

Supongamos que tenemos q funciones estimables $\psi_1, \psi_2, \dots, \psi_q$ donde:

$$\psi_i = \sum_{j=1}^p c_{ij} \beta_j \quad 1 \leq i \leq q$$

Por ser estimables, por el Teorema de Gauss–Markov tenemos que

$$\widehat{\psi}_i = \sum_{j=1}^n a_{ij}^* y_j \quad 1 \leq i \leq q,$$

donde $\mathbf{a}_i^* \in \mathcal{V}_r \subset \mathfrak{R}^n$; de manera que

$$\begin{aligned} \boldsymbol{\psi} &= \mathbf{C}\boldsymbol{\beta} & \mathbf{C} &\in \mathfrak{R}^{q \times p} \\ \widehat{\boldsymbol{\psi}} &= \mathbf{A}^* \mathbf{Y} & \mathbf{A}^* &\in \mathfrak{R}^{q \times n} \end{aligned}$$

Más aún, sabemos que

$$\begin{aligned} \widehat{\boldsymbol{\psi}} &= \mathbf{C}\widehat{\boldsymbol{\beta}} \\ \boldsymbol{\Sigma}_{\widehat{\boldsymbol{\psi}}} &= \sigma^2 \mathbf{A}^* \mathbf{A}^{*'} \end{aligned}$$

Estimamos a σ^2 por

$$s^2 = \frac{\|\mathbf{Y} - \widehat{\mathbf{Y}}\|^2}{n - r}$$

Bajo estas nuevas hipótesis obtenemos el siguiente resultado:

Teorema: Supongamos que se cumple Ω , es decir $\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I})$, $\text{rg}(\mathbf{X}) = r$, $\boldsymbol{\beta} \in \mathbb{R}^p$ y que además que $\psi_1, \psi_2, \dots, \psi_q$ son q funciones estimables l.i., de manera que $\text{rg}(\mathbf{C}) = q$. Entonces,

- i) $\widehat{\Psi} \sim N_q(\Psi, \Sigma_{\widehat{\Psi}})$ (o lo que es igual $N_q(\Psi, \sigma^2\mathbf{A}^*\mathbf{A}^{\prime})$)
- ii) $\widehat{\Psi}$ y $\frac{s^2(n-r)}{\sigma^2}$ son independientes
- iii) $\frac{(n-r)s^2}{\sigma^2} \sim \chi_{n-r}^2$

En el caso de rango completo, es decir cuando $r = p$, obtenemos el siguiente resultado:

Teorema: Supongamos que se cumple Ω , es decir $\mathbf{Y} \sim N_n(\mathbf{X}\boldsymbol{\beta}, \sigma^2\mathbf{I})$, $\text{rg}(\mathbf{X}) = p$, $\boldsymbol{\beta} \in \mathcal{R}^p$. Entonces,

$$\text{i) } \widehat{\boldsymbol{\beta}} \sim N_p(\boldsymbol{\beta}, \sigma^2(\mathbf{X}'\mathbf{X})^{-1})$$

$$\text{ii) } \frac{(\widehat{\boldsymbol{\beta}} - \boldsymbol{\beta})'(\mathbf{X}'\mathbf{X})(\widehat{\boldsymbol{\beta}} - \boldsymbol{\beta})}{\sigma^2} \sim \chi_p^2$$

iii) $\widehat{\boldsymbol{\beta}}$ y $\frac{(n-p)s^2}{\sigma^2}$ son independientes

$$\text{iv) } \frac{(n-p)s^2}{\sigma^2} \sim \chi_{n-p}^2$$

Estos resultados nos permiten deducir intervalos de confianza o tests para cada uno de los coeficientes del modelo lineal:

Como $\widehat{\boldsymbol{\beta}} \sim N_p(\boldsymbol{\beta}, \sigma^2(\mathbf{X}'\mathbf{X})^{-1})$, entonces $\widehat{\beta}_i = \mathbf{e}_i'\widehat{\boldsymbol{\beta}} \sim N(\beta_i, \sigma^2\mathbf{e}_i'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{e}_i)$.
 Si denotamos $\Sigma_{\widehat{\boldsymbol{\beta}}} = \sigma^2\mathbf{D}$

$$\widehat{\beta}_i \sim N(\beta_i, \sigma^2 d_{ii})$$

siendo d_{ii} el i -ésimo elemento diagonal de \mathbf{D} .

Si para un i fijo queremos testear

$$H_0 : \beta_i = 0 \quad \text{vs.} \quad H_1 : \beta_i \neq 0$$

tenemos que bajo H_0

$$\frac{\widehat{\beta}_i}{s\sqrt{d_{ii}}} \sim t_{n-p}$$

Por lo tanto, rechazaremos H_0 con nivel α si

$$\left| \frac{\widehat{\beta}_i}{s\sqrt{d_{ii}}} \right| > t_{n-p, \frac{\alpha}{2}}$$

En el caso de regresión simple tendríamos

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i, \quad 1 \leq i \leq n, \quad \epsilon_i \sim N(0, \sigma^2)$$

Entonces:

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} n & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix}$$

y la inversa resulta

$$(\mathbf{X}'\mathbf{X})^{-1} = \frac{1}{n \sum_{i=1}^n x_i^2 - n^2 \bar{x}^2} \begin{pmatrix} \sum_{i=1}^n x_i^2 & - \sum_{i=1}^n x_i \\ - \sum_{i=1}^n x_i & n \end{pmatrix}$$

$$\widehat{\beta}_0 = -\bar{x}\widehat{\beta}_1 + \bar{y}$$

y

$$\widehat{\beta}_1 = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Luego, si queremos testear

$$H_0 : \beta_1 = 0 \quad \text{vs.} \quad H_1 : \beta_1 \neq 0$$

el estadístico será

$$T = \left| \frac{\widehat{\beta}_1}{s\sqrt{d_{11}}} \right| = \left| \frac{\widehat{\beta}_1}{s/\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}} \right|$$

y rechazaremos H_0 si

$|T| > t_{n-2, \frac{\alpha}{2}}$

Veamos un ejemplo: Precio del papel.


Y: ganancia en 1972

x: precio de papel en 1973

> Ejemplo Precio del Papel

precio ganancia

	x	y
1	1.83	28
2	3.35	45
3	0.64	12
4	2.30	35
5	2.39	45
6	1.08	14
7	2.92	39
8	1.11	12
9	2.57	43
10	1.22	23



```
> sal.lm
Coefficients:
(Intercept)          x
      2.027775      14.20517

Degrees of freedom: 10 total; 8 residual
Residual standard error: 5.025083

> summary(sal.lm)

Call: lm(formula = y ~ x, x = T)

Residuals:
    Min       1Q   Median       3Q      Max
-5.796  -4.222   0.1386   2.952   9.022
```


Coefficients:

	Value	Std. Error	t value	Pr(> t)
(Intercept)	2.0278	3.9383	0.5149	0.6206
x	14.2052	1.8565	7.6516	0.0001

Residual standard error: 5.025 on 8 degrees of freedom

Multiple R-Squared: 0.8798

F-statistic: 58.55 on 1 and 8 degrees of freedom, the p-value is 0.00006008

Correlation of Coefficients:

(Intercept)

x -0.915

X'X=

(Intercept)

x

(Intercept)

19.4100

x

19.41

45.0013

```
(X'X)^(-1) =
      (Intercept)      x
(Intercept)  0.6142273  -0.264929
x           -0.2649290   0.136491
```

> matriz de covarianza de coeficientes

```
      (Intercept)      x
(Intercept)  15.510133  -6.689844
x           -6.689844   3.446597
```

También podríamos interesarnos realizar in l. de C. para la esperanza de una nueva observación **independiente de las demás** que cumpla el modelo

$$y_i = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \epsilon_i$$

en $\mathbf{x}_o = (\mathbf{x}_{o1}, \mathbf{x}_{o2}, \dots, \mathbf{x}_{op})'$ donde $\epsilon_i \sim N(0, \sigma^2)$ independientes.

Como $E(y_o) = \mathbf{x}'_o \boldsymbol{\beta}$, podemos estimarlo por $E(\widehat{y}_o) = \mathbf{x}'_o \widehat{\boldsymbol{\beta}} = \widehat{y}_o$

Por lo tanto, de acuerdo con lo que hemos visto

$$\widehat{y}_o = \mathbf{x}'_o \widehat{\boldsymbol{\beta}} \sim N(\mathbf{x}'_o \boldsymbol{\beta}, \sigma^2 \mathbf{x}'_o (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_o)$$

y es independiente de

$$\frac{(n-p)s^2}{\sigma^2} \sim \chi_{n-p}^2$$

por lo tanto

$$T = \frac{\widehat{y}_o - \mathbf{x}'_o \boldsymbol{\beta}}{s \sqrt{\mathbf{x}'_o (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_o}} \sim t_{n-p}$$

En consecuencia,

$$\hat{y}_o \pm t_{n-2, \frac{\alpha}{2}} S \sqrt{\mathbf{x}'_o (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_o}$$

es un intervalo de nivel exacto $1 - \alpha$.

Asimismo, podríamos estar interesados en la predicción de y_o , una nueva observación que cumpla el modelo, y en un intervalo para ella, que llamaremos **intervalo de predicción**.

Observemos que el predictor de y_o es $\hat{y}_o = \mathbf{x}'_o \hat{\boldsymbol{\beta}}$. En efecto, $E(\hat{y}_o - y_o) = 0$. **¿Qué distribución tiene $\hat{y}_o - y_o$?**

Tenemos que

$$\begin{aligned} \hat{y}_o &\sim N(\mathbf{x}'_o \boldsymbol{\beta}, \sigma^2 \mathbf{x}'_o (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_o) \\ y_o &\sim N(\mathbf{x}'_o \boldsymbol{\beta}, \sigma^2) \end{aligned}$$

y dado que y_o es independiente de las restantes y_i 's con las que estimamos, entonces por la independencia entre estas dos normales queda que

$$\hat{y}_o - y_o \sim N(0, \sigma^2(1 + \mathbf{x}'_o(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}_o))$$

Por lo tanto, el intervalo de predicción de nivel $1 - \alpha$ estará dado por

$$\hat{y}_o \pm t_{n-2, \frac{\alpha}{2}} s \sqrt{1 + \mathbf{x}'_o(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}_o}$$

Ejemplo. Los siguientes son datos que corresponden a 10 porcentajes y_i de una sustancia que fueron medidos en experiencias de laboratorio y que se desean relacionar con la temperatura x_i a la que fueron realizados dichas experiencias.

i	x	y
1	100	45
2	110	52
3	120	54
4	130	63
5	140	62
6	150	68
7	160	75
8	170	76
9	180	92
10	190	88

La tabla con los estadísticos calculados es:

Coefficiente	Estimación	Error Standard	Valor de t
β_0	-4.47273	5.63433	-0.79
β_1	0.49636	0.03812	13.02
s	3.46213	g.l.=8	

Intervalos de Estimación y de Predicción




Tabla de Resultados

UNWEIGHTED LEAST SQUARES LINEAR REGRESSION OF Y					
PREDICTOR VARIABLES	COEFFICIENT	STD ERROR	STUDENT'S T	P	
CONSTANT	-4.47273	5.63433	-0.79	0.4502	
X	0.49636	0.03812	13.02	0.0000	
R-SQUARED	0.9549		RESID. MEAN SQUARE (MSE)	11.9864	
ADJUSTED R-SQUARED	0.9493		STANDARD DEVIATION	3.46213	
SOURCE	DF	SS	MS	F	P
REGRESSION	1	2032.61	2032.61	169.58	0.0000
RESIDUAL	8	95.8909	11.9864		
TOTAL	9	2128.50			
CASES INCLUDED		10	MISSING CASES 0		

- El valor estimado de $\hat{\beta}_1 \simeq 0,5$, \Rightarrow esperamos que el porcentaje aumente 0.5 por cada incremento de un grado en la temperatura.
- $s_{\hat{\beta}_1} = 0,038112$
- Si testeamos $H_0 : \beta_1 = 0$ $t = \frac{0,49636}{0,038112} = 13,02$ y $t_{8,0,025} = 2,306004$
 \Rightarrow los datos nos dan evidencia suficiente al nivel 5 % como para concluir que la pendiente es no nula.