





Estadística Ciencias Ambientales
Facultad de Ciencias
Departamento de Matemáticas
Profesor: Santiago de la Fuente Fernández

REGRESIÓN LINEAL MÚLTIPLE





REGRESIÓN LINEAL MÚLTIPLE

Las técnicas de regresión lineal múltiple parten de $k+1$ variables cuantitativas, siendo Y la variable de respuesta y (x_1, \dots, x_k) las variables explicativas.

Se trata de extender a las 'k' variables las técnicas de la regresión lineal simple. En esta línea, la variable Y se puede expresar mediante una función lineal de las variables (x_1, \dots, x_k)

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$$

Para ello, dispondremos de un modelo de probabilidad (la Normal).

El experimentador fija los valores de las X_{ki} y obtiene 'al azar' los correspondientes Y_i

$$\text{Modelo: } Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + U$$

REGRESIÓN LINEAL MÚLTIPLE - MUESTRA ALEATORIA

$$\text{Modelo: } \mathbf{Y} = \beta_0 + \beta_1 \mathbf{X}_1 + \beta_2 \mathbf{X}_2 + \cdots + \beta_k \mathbf{X}_k + \mathbf{U}$$

Sea la muestra aleatoria:

$$\mathbf{Y}_i = \beta_0 + \beta_1 \mathbf{X}_{1i} + \beta_2 \mathbf{X}_{2i} + \cdots + \beta_k \mathbf{X}_{ki} + \mathbf{u}_i \quad (i = 1, 2, \dots, n)$$

$\mathbf{Y}_i \in N(\beta_0 + \beta_1 \mathbf{X}_1 + \cdots + \beta_k \mathbf{X}_k, \sigma^2)$ independientes, $(i=1, \dots, n)$

$\mathbf{u}_i \in N(0, \sigma^2)$ independientes, $(i=1, \dots, n)$

$$\begin{pmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_n \end{pmatrix} = \begin{pmatrix} 1 & \mathbf{X}_{11} & \cdots & \mathbf{X}_{k1} \\ 1 & \mathbf{X}_{12} & \cdots & \mathbf{X}_{k2} \\ \vdots & \vdots & \cdots & \vdots \\ 1 & \mathbf{X}_{1n} & \cdots & \mathbf{X}_{kn} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} + \begin{pmatrix} \mathbf{u}_1 \\ \mathbf{u}_2 \\ \vdots \\ \mathbf{u}_n \end{pmatrix}$$

$$\mathbf{Y} = \mathbf{X}\beta + \mathbf{U} \quad \mathbf{X} = \text{matriz del diseño}$$

Hipótesis comunes entre regresiones lineal y múltiple:

- Normalidad
- Homocedasticidad
- Linealidad
- Independencia

Requisitos adicionales de la regresión múltiple:

- $n > k+1$

El modelo depende de $(k+2)$ parámetros. Para que la regresión tenga significado debe haber un número suficiente de datos.

- **Ninguna X es combinación lineal de las otras (colinealidad)**

Si alguna de las X_i es combinación lineal exacta de algunas de las otras X_i , el modelo puede simplificarse con menos variables explicativas. También hay que considerar si alguna de las X_i está fuertemente correlacionada con otras.

DATOS - ESTIMACIÓN DE LOS PARÁMETROS

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i$$

$$\boxed{Y = X\beta + U} \quad \text{donde} \quad X = \text{matriz del diseño}$$

Datos	Y	X ₁	...	X _k
1	y ₁	x ₁₁	...	x _{k1}
2	y ₂	x ₁₂	...	x _{k2}
⋮	⋮	⋮	...	⋮
n	y _n	x _{1n}	...	x _{kn}

La nube de puntos está en un espacio de dimensión (k+1).

Difícil de visualizar para k>2

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

X' = matriz transpuesta

$$e_i = y_i - \hat{y}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki})$$

$$\hat{\sigma}_r^2 = S_R^2 = \frac{1}{n - k - 1} \sum_{i=1}^n e_i^2 \quad \text{varianza residual}$$

NOTA. - Al igual que en regresión simple, necesitamos estimar la varianza σ^2 del error aleatorio U .

Un estimador razonable, en un principio, es la varianza de los errores de predicción (también denominados como residuos del modelo).

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n e_i^2$$

Sin embargo, este estimador es sesgado para σ^2 , lo que significa que $E(\hat{\sigma}^2) \neq \sigma^2$

El sesgo se define como la diferencia entre la media del estimador y el verdadero valor del parámetro que se quiere estimar.

Utilizamos, por tanto, la varianza residual para estimar σ^2 , que sí es un estimador insesgado de σ^2 , es decir, centrado en torno a σ^2

$$\hat{\sigma}_r^2 = S_R^2 = \frac{1}{n - k - 1} \sum_{i=1}^n e_i^2$$

RELACIONES ENTRE LAS VARIABLES

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

$$\hat{Y} = X \hat{\beta} = \boxed{X (X' X)^{-1} X'} Y = H Y$$

H matriz de la proyección

La matriz H cumple las propiedades

Idempotente: $H \cdot H = H$

Simétrica: $H' = H$

Rango: $\text{rango}(X) = \text{rango } H = k+1$

El error de predicción se puede escribir en forma matricial:

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

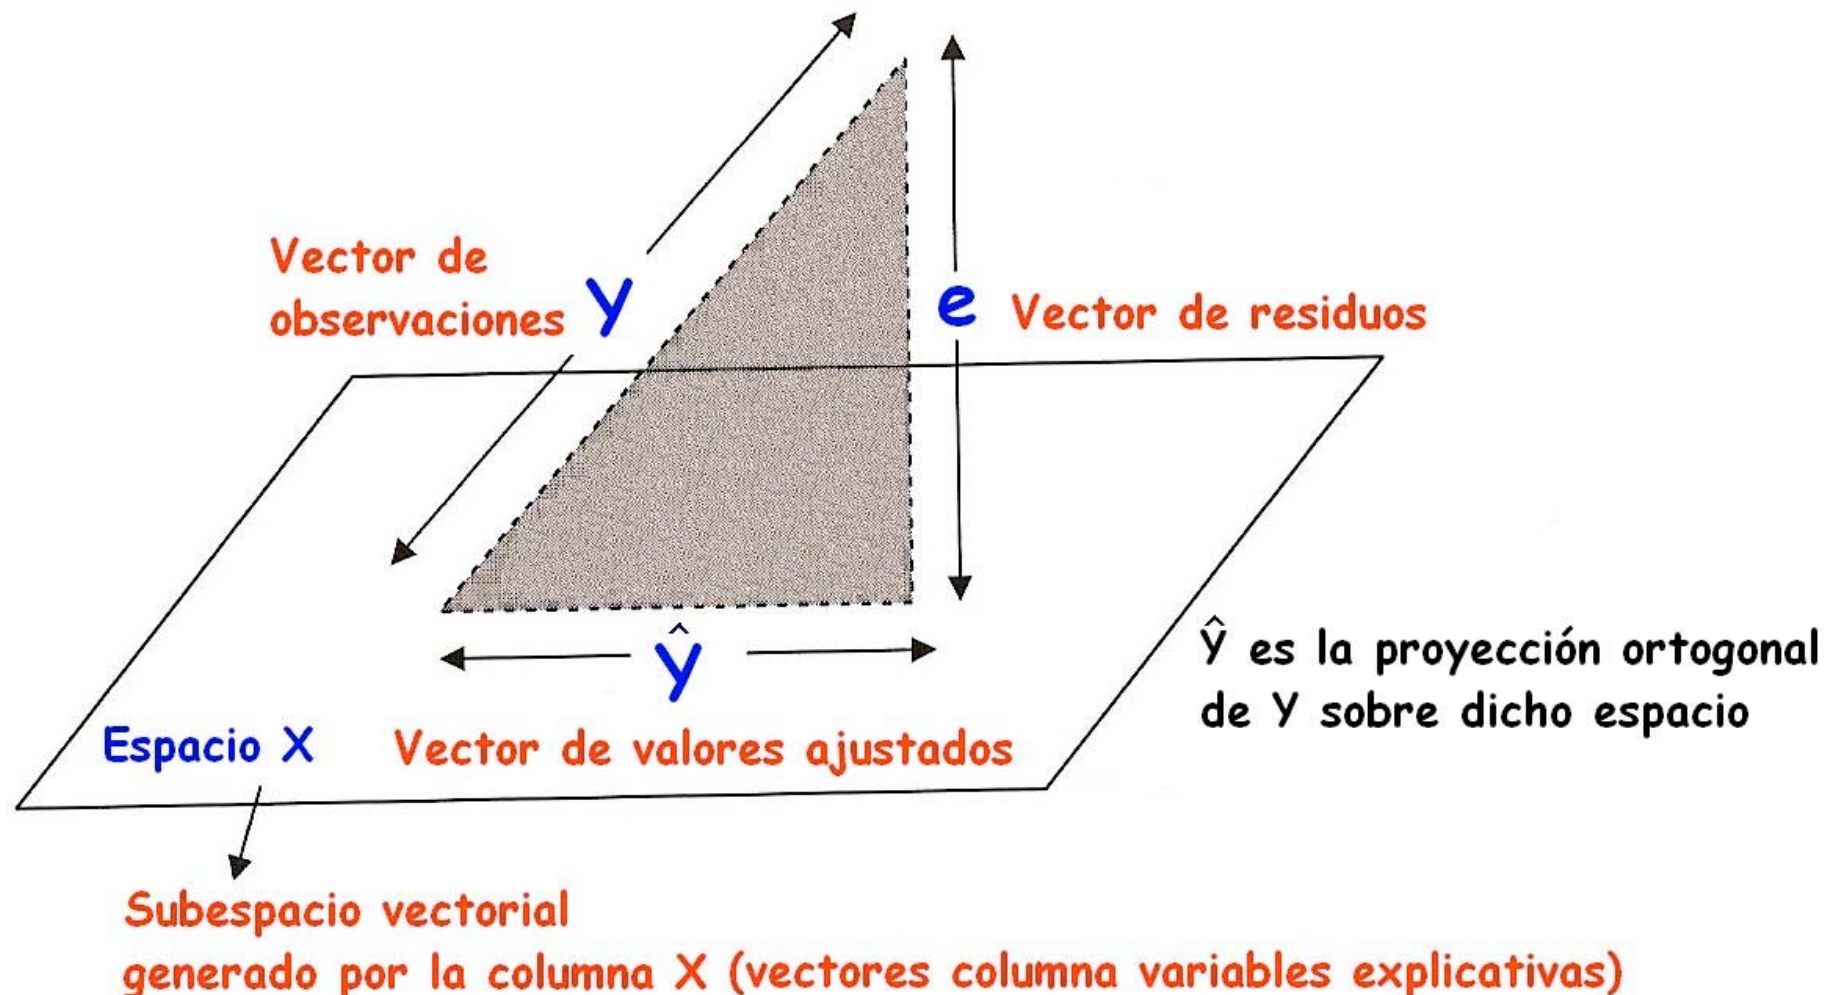
La expresión $\hat{Y} = H Y$ indica que la matriz **H** (idempotente) transforma el vector de las observaciones **Y** en el vector de valores ajustados (predicción) \hat{Y} , siendo la regresión una proyección.

El modelo regresión $\hat{Y} = H Y$ proyecta el valor de observaciones sobre el subespacio vectorial de las columnas de la matriz X (subespacio de las variables independientes).

El vector de residuos es perpendicular a cada columna de **X** y al vector de predicción \hat{Y}

INTERPRETACIÓN GEOMÉTRICA

El método de los mínimos cuadrados, en el espacio formado por las variables, es equivalente a encontrar un vector en dicho espacio que se encuentre lo más cercano posible al vector de las observaciones.



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

$$\mathbf{Y} = \mathbf{X}\beta + \mathbf{U}$$

El correspondiente modelo ajustado será: $\hat{\mathbf{Y}} = \mathbf{X}\hat{\beta}$

$$\hat{\mathbf{U}} = \mathbf{Y} - \hat{\mathbf{Y}} = \mathbf{Y} - \mathbf{X}\hat{\beta}$$

Denominando S a la suma de los cuadrados de los residuos:

$$S = \hat{\mathbf{U}}' \hat{\mathbf{U}} = [\hat{u}_1, \hat{u}_2, \dots, \hat{u}_n] \begin{bmatrix} \hat{u}_1 \\ \hat{u}_2 \\ \vdots \\ \hat{u}_n \end{bmatrix} = \sum_{i=1}^n \hat{u}_i^2$$

(A' = matriz transpuesta A)

Un escalar es igual
a su transpuesto:
 $\hat{\beta}' \mathbf{X}' \mathbf{Y} = \mathbf{Y}' \mathbf{X} \hat{\beta}$

$$\begin{aligned} S &= (\mathbf{Y} - \mathbf{X}\hat{\beta})' (\mathbf{Y} - \mathbf{X}\hat{\beta}) = \\ &= \mathbf{Y}' \mathbf{Y} - \hat{\beta}' \mathbf{X}' \mathbf{Y} - \mathbf{Y}' \mathbf{X} \hat{\beta} + \hat{\beta}' \mathbf{X}' \mathbf{X} \hat{\beta} = \\ &= \mathbf{Y}' \mathbf{Y} - 2\hat{\beta}' \mathbf{X}' \mathbf{Y} + \hat{\beta}' \mathbf{X}' \mathbf{X} \hat{\beta} \end{aligned}$$

$$S = (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})' (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}) = \mathbf{Y}'\mathbf{Y} - 2\hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{Y} + \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}}$$

Para minimizar S se aplica el criterio mínimo-cuadrático, derivando respecto $\hat{\boldsymbol{\beta}}$

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

$$\begin{aligned} (\mathbf{X}'\mathbf{X})^{-1} (\mathbf{X}'\mathbf{X}) \hat{\boldsymbol{\beta}} &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} \\ \Rightarrow \underline{\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}} \end{aligned}$$

DISTRIBUCIÓN de $\hat{\beta}$

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

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

matriz de proyección

- El vector de observaciones \mathbf{Y} se distribuye según una normal multivariante de media $\mathbf{X}\beta$ y de matriz de varianzas covarianzas $\sigma^2 \mathbf{I}$

$$\mathbf{Y} \varepsilon \mathbf{N}(\mathbf{X}\beta, \sigma^2 \mathbf{I})$$

- $\hat{\beta}$ es combinación lineal de las componentes del vector \mathbf{Y} , por lo que se distribuye según una variable aleatoria normal, donde su media y matriz de varianzas y covarianzas será:

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

$\hat{\beta}$ es un estimador centrado de β

$$\begin{aligned}\text{Var}(\hat{\beta}) &= \text{Var}[(X'X)^{-1} X'Y] = (X'X)^{-1} X' \text{Var}(Y) X(X'X)^{-1} = \\ &= (X'X)^{-1} X' \sigma^2 X(X'X)^{-1} = \sigma^2 (X'X)^{-1}\end{aligned}$$

$$\hat{\beta} \varepsilon N(\beta, \sigma^2 (X'X)^{-1})$$

- Con el ajuste de mínimos cuadrados:

$$e_i = y_i - \hat{y}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki})$$

parámetros estimados del modelo

$$\hat{\beta}_i \varepsilon N(\beta_i, \sigma^2 q_{ii}) \quad q_{ii} \text{ es el elemento } i\text{-ésimo de la diagonal principal } (X'X)^{-1}$$

La estimación de σ^2 se hacía mediante la varianza residual $\hat{S}_R^2 = \frac{1}{n-k-1} \sum_{i=1}^n e_i^2$

De forma que estimaremos la varianza de $\hat{\beta}_i \varepsilon N(\beta_i, \sigma^2 q_{ii})$ mediante $\hat{S}_R^2 q_{ii}$

El error estándar de $\hat{\beta}_i$ viene dado por: $SE(\hat{\beta}_i) = \sqrt{\hat{S}_R^2 q_{ii}} = \hat{S}_R \sqrt{q_{ii}}$

Se demuestra que $\frac{(n-k-1)\hat{S}_R^2}{\sigma^2} \approx \chi_{n-k-1}^2$

Contraste t - Student

Los parámetros del modelo estimado $\hat{\beta}_i \in N(\beta_i, \sigma^2 q_{ii})$ siendo q_{ii} el elemento i -ésimo de la diagonal principal $(X'X)^{-1}$

De forma estándar, se obtiene $\frac{\hat{\beta}_i - \beta_i}{\sigma \sqrt{q_{ii}}} \approx N(0, 1)$

Una variable t de Student con k -grados de libertad, se define $t_k = \frac{N(0, 1)}{\sqrt{\frac{1}{k} \chi_k^2}}$

Considerando que $\frac{(n-k-1)\hat{S}_R^2}{\sigma^2} \approx \chi_{n-k-1}^2$ resulta:

$$t = \frac{\frac{\hat{\beta}_i - \beta_i}{\sigma \sqrt{q_{ii}}}}{\sqrt{\frac{1}{n-k-1} \frac{(n-k-1)\hat{S}_R^2}{\sigma^2}}} = \frac{\hat{\beta}_i - \beta_i}{\hat{S}_R \sqrt{q_{ii}}} \approx t_{n-k-1}$$

Planteando la hipótesis nula $H_0: \beta_i = 0$ frente a la hipótesis alternativa $H_a: \beta_i \neq 0$ es decir, si el valor del parámetro en la población es cero o no. En otras palabras, si la variable X_i influye sobre la variable respuesta Y .

Siendo $t = \frac{\hat{\beta}_i - \beta_i}{\hat{S}_R \sqrt{q_{ii}}} \approx t_{n-k-1}$ Al establecer la hipótesis nula $H_0: \beta_i = 0$ es decir, el valor del parámetro en la población es cero. Esto es, la variable X_i no influiría sobre la variable respuesta Y .

Bajo la hipótesis nula, siendo $\beta_i = 0$, resulta: $t = \frac{\hat{\beta}_i}{\hat{S}_R \sqrt{q_{ii}}} \approx t_{n-k-1}$

■ En definitiva, siendo la hipótesis nula $H_0: \beta_i = 0$

Aceptamos la hipótesis nula cuando el valor del estadístico t proviene de una t_{n-k-1}

Para $n > 30$ se acepta la hipótesis nula H_0 cuando $|t| \leq 2$

En caso contrario, se acepta la hipótesis alternativa H_a y se concluye que la variable i -ésima influye en la respuesta.

INTERVALOS DE CONFIANZA para β_i

Estimación de los parámetros: $\hat{\beta} = (\mathbf{X}' \mathbf{X})^{-1} \mathbf{X}' \mathbf{Y}$ $\mathbf{X}' =$ matriz transpuesta

$$\mathbf{IC}_{1-\alpha}(\beta_i) = \left(\hat{\beta}_i \pm t_{(n-k-1); \alpha/2} \mathbf{S}_r \sqrt{q_{i+1, i+1}} \right)$$

Desviación típica (error típico)
estimada de $\hat{\beta}_i$

$q_{i+1, i+1} \equiv$ elementos de la diagonal principal $(\mathbf{X}' \mathbf{X})^{-1}$

$$\mathbf{S}_r^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - k - 1}$$

INTERVALOS DE CONFIANZA para β_i

Estimación de los parámetros: $\hat{\beta} = (\mathbf{X}' \mathbf{X})^{-1} \mathbf{X}' \mathbf{Y}$ $\mathbf{X}' =$ matriz transpuesta

$$\text{IC}_{1-\alpha} (\beta_i) = \left(\hat{\beta}_i \pm t_{(n-k-1); \alpha/2} \sqrt{s_r q_{i+1, i+1}} \right)$$

$q_{i+1, i+1} \equiv$ elementos de la diagonal principal $(\mathbf{X}'\mathbf{X})^{-1}$ Desviación típica estándar (error típico)

CONTRASTES DE HIPÓTESIS

Hipótesis nula $\mathbf{H}_0 : \beta_i = 0$ X_i no influye en Y

Hipótesis alternativa $\mathbf{H}_1 : \beta_i \neq 0$ X_i influye en Y

Se acepta la hipótesis nula H_0 , con un nivel de confianza $(1 - \alpha)$ cuando el 0 se encuentra en el intervalo de confianza.

En caso contrario, cuando el 0 no cae en el intervalo de confianza, se acepta la hipótesis alternativa H_1 , y en consecuencia, X_i influye en Y

Este contraste es equivalente al contraste de la t-Student para cada β_i

DESCOMPOSICIÓN DE LA VARIABILIDAD

$$\begin{aligned} \text{SCT} &= \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n [(y_i - \hat{y}_i) + (\hat{y}_i - \bar{y})]^2 = \\ &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \underbrace{2 \sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y})}_0 \end{aligned}$$

$$\underbrace{\sum_{i=1}^n (y_i - \bar{y})^2}_{\text{SCT}} = \underbrace{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}_{\text{SCE}} + \underbrace{\sum_{i=1}^n (y_i - \hat{y}_i)^2}_{\text{SCR}}$$

Suma cuadrados total Suma cuadrados explicada Suma cuadrados residual

$$\text{Coeficiente de determinación } R^2 = \frac{\text{SCE}}{\text{SCT}} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

ANÁLISIS de la VARIANZA - TABLA ANOVA

$$\underbrace{\sum_{i=1}^n (y_i - \bar{y})^2}_{\text{SCT}} = \underbrace{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}_{\text{SCE}} + \underbrace{\sum_{i=1}^n (y_i - \hat{y}_i)^2}_{\text{SCR}}$$

(n-1) grados libertad k grados libertad (n-k-1) grados libertad

Variación	Suma cuadrados	g.l	Media cuadrática	F-Snedecor
Explicada	$\text{SCE} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$	k	SCE/k	$F = \frac{\text{SCE/k}}{\text{SCR}/(n-k-1)}$
Residual	$\text{SCR} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$	n-k-1	SCR/(n-k-1)	
Total	$\text{SCT} = \sum_{i=1}^n (y_i - \bar{y})^2$	n-1		

Se establecen las hipótesis:

$H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0$ el modelo no es explicativo

$H_1 : \text{al menos un } \beta_i \neq 0$ el modelo es explicativo

A un nivel de confianza $(1-\alpha)$ se rechaza H_0 si $F \geq F_{k, (n-k-1); \alpha}$

COEFICIENTES de DETERMINACIÓN - F de Snedecor

$$R^2 = \frac{SCE}{SCT} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

$$F = \frac{SCE/k}{SCR/(n-k-1)} = \frac{SCE}{SCT} \frac{SCT}{SCR} \frac{n-k-1}{k} = R^2 \frac{1}{\frac{SCR}{SCT}} \frac{n-k-1}{k} =$$

$$= R^2 \frac{1}{\frac{SCT - SCE}{SCT}} \frac{n-k-1}{k} = R^2 \frac{1}{1 - R^2} \frac{n-k-1}{k} = \frac{R^2}{1 - R^2} \frac{n-k-1}{k}$$

$$F = \frac{R^2}{1 - R^2} \frac{n - k - 1}{k}$$

RESUMEN de los CONTRASTES

Contraste Conjunto F-Snedecor	Contrastes Individuales t-Sudent	Conclusión
Modelo explicativo	Todas las X_i son explicativas	Tomamos todas las X_i
Modelo explicativo	Algunas X_i son explicativas	Nos quedamos con las X_i explicativas
Modelo explicativo	Ninguna X_i es explicativa	Posible Multicolinealidad revisar el modelo
Modelo no explicativo	Todas las X_i son explicativas	Posible Multicolinealidad revisar el modelo
Modelo no explicativo	Algunas X_i son explicativas	Posible Multicolinealidad revisar el modelo
Modelo no explicativo	Ninguna X_i es explicativa	El modelo no explica Y

- Estimación de la respuesta media de Y para los valores $(x_{10}, x_{20}, \dots, x_{k0})$ de las variables explicativas.

$$\hat{y}_0 = \hat{\beta}_0 + \hat{\beta}_1 x_{10} + \hat{\beta}_2 x_{20} + \dots + \hat{\beta}_k x_{k0}$$

$$\mathbf{IC}_{1-\alpha} = \left(\hat{y}_0 \pm t_{(n-k-1), \alpha/2} S_r \sqrt{\left(1 \ x_{10} \ x_{20} \ \dots \ x_{k0} \right) (X'X)^{-1} \begin{pmatrix} 1 \\ x_{10} \\ x_{20} \\ \vdots \\ x_{k0} \end{pmatrix}} \right)$$

- Predicción de un nuevo valor de Y para los valores $(x_{10}, x_{20}, \dots, x_{k0})$ de las variables explicativas.

$$\mathbf{IP}_{1-\alpha} = \left(\hat{y}_0 \pm t_{(n-k-1), \alpha/2} S_r \sqrt{1 + \left(1 \ x_{10} \ x_{20} \ \dots \ x_{k0} \right) (X'X)^{-1} \begin{pmatrix} 1 \\ x_{10} \\ x_{20} \\ \vdots \\ x_{k0} \end{pmatrix}} \right)$$