

**Ejemplo:****Significación de la Regresión. Tabla de Análisis de la Varianza**

Supongamos que tenemos el modelo con intercept dado por

$$E(\mathbf{Y}) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_{p-1} x_{p-1}$$

y queremos testear

$$H_o : \beta_1 = \beta_2 = \dots = \beta_{p-1} = 0$$

de manera que  $\omega = \Omega \cap H$ .  $H$  impone  $p - 1$  restricciones l.i. Trataremos el caso en que  $\text{rg}(\mathbf{X}) = p$

¿Quién es  $\mathcal{V}_\omega$ ?

$\dim(\mathcal{V}_\omega) = r - (p - 1) = p - (p - 1) = 1$  y tenemos que  $\mathcal{V}_1 \in \mathcal{V}_p$

¿Quién es  $\hat{\eta}_\omega$ ?

Bajo  $\omega$ ,  $\beta_1 = \dots = \beta_{p-1} = 0$ ,  $E(\mathbf{Y}) = \beta_0$ .

Tenemos que:

$$\mathbf{X}_\omega = \begin{pmatrix} 1 \\ 1 \\ \cdot \\ \cdot \\ 1 \end{pmatrix} \rightarrow \widehat{\beta}_0 = (\mathbf{X}'_\omega \mathbf{X}_\omega)^{-1} \mathbf{X}'_\omega \mathbf{Y} = \frac{1}{n} \sum_{i=1}^n y_i = \bar{\mathbf{Y}}.$$

Luego:

$$\widehat{\eta}_\omega = \mathbf{X}'_\omega \widehat{\beta}_0 = \begin{pmatrix} \bar{\mathbf{Y}} \\ \bar{\mathbf{Y}} \\ \cdot \\ \cdot \\ \bar{\mathbf{Y}} \end{pmatrix}$$

Además:

$$\|\mathbf{Y}\|^2 = \|\mathbf{Y} - \widehat{\eta}\|^2 + \|\widehat{\eta} - \widehat{\eta}_\omega\|^2 + \|\widehat{\eta}_\omega\|^2$$

Bajo  $\Omega$  si  $\text{rg}(\mathbf{X}) = p$

$$\widehat{\beta}_\Omega = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} \rightarrow \widehat{\eta} = \mathbf{P}\mathbf{Y} \text{ donde } \mathbf{P} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'$$

En efecto,  $\hat{\boldsymbol{\eta}}_{\omega}$  es la proyección ortogonal de  $\hat{\boldsymbol{\eta}}$  sobre  $\mathcal{V}_{\omega} = \mathcal{V}_1$ . Si fuera así, entonces  $\hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_{\omega} \perp \hat{\boldsymbol{\eta}}_{\omega}$ .

$$\hat{\boldsymbol{\eta}} = \mathbf{P}\mathbf{Y} \text{ y } \hat{\boldsymbol{\eta}}_{\omega} = \mathbf{1}(\mathbf{1}'\mathbf{1})^{-1}\mathbf{1}'\mathbf{Y} = \mathbf{P}_1\mathbf{Y}$$

luego,

$$(\hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_{\omega})'\hat{\boldsymbol{\eta}}_{\omega} = \mathbf{Y}'(\mathbf{P} - \mathbf{P}_{\omega})\mathbf{P}_{\omega}\mathbf{Y} = \mathbf{Y}'(\mathbf{P}\mathbf{P}_{\omega} - \mathbf{P}'_{\omega}\mathbf{P}_{\omega})\mathbf{Y} = \mathbf{Y}'(\mathbf{P}_{\omega} - \mathbf{P}_{\omega})'\mathbf{P}_{\omega}\mathbf{Y} = \mathbf{0}$$

$$\|\mathbf{Y}\|^2 = \|\mathbf{Y} - \hat{\boldsymbol{\eta}}\|^2 + \|\hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_{\omega}\|^2 + \|\hat{\boldsymbol{\eta}}_{\omega}\|^2$$

Llamaremos

$\|\mathbf{Y}\|^2$ : suma de cuadrados total

$\|\mathbf{Y} - \hat{\boldsymbol{\eta}}\|^2$ : suma de cuadrados residual

$\|\hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_{\omega}\|^2$ : suma de cuadrados de la regresión

$\|\mathbf{Y} - \hat{\boldsymbol{\eta}}_{\omega}\|^2$ : suma de cuadrados total corregida

Tenemos las siguientes igualdades

$$\begin{aligned} \|\mathbf{Y}\|^2 &= \mathbf{Y}'\mathbf{Y} && \text{g.l.} = n \\ \|\mathbf{Y} - \hat{\boldsymbol{\eta}}\|^2 &= \mathbf{Y}'\mathbf{Y} - \hat{\boldsymbol{\beta}}'\mathbf{X}\mathbf{Y} && \text{g.l.} = n - p \\ \|\hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_{\omega}\|^2 &= \hat{\boldsymbol{\beta}}'\mathbf{X}\mathbf{Y} - n(\bar{\mathbf{Y}})^2 && \text{g.l.} = p - 1 \\ \|\mathbf{Y} - \hat{\boldsymbol{\eta}}_{\omega}\|^2 &= \mathbf{Y}'\mathbf{Y} - n(\bar{\mathbf{Y}})^2 && \text{g.l.} = n - 1 \end{aligned}$$

Si quisiéramos verificar la significación de la regresión, haríamos

$$F = \frac{\|\hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_w\|^2 / p - 1}{\|\mathbf{Y} - \hat{\boldsymbol{\eta}}\|^2 / n - p}$$

Muchos programas ofrecen en su salida una tabla como la que sigue

Fuente		g.l.	M.S.	F	p-valor
Regresión	$\ \hat{\boldsymbol{\eta}}\ ^2 - n(\bar{\mathbf{Y}})^2$	$p - 1$	$(1) = \frac{\ \hat{\boldsymbol{\eta}}\ ^2 - n(\bar{\mathbf{Y}})^2}{p-1}$		
Residual	$\ \mathbf{Y} - \hat{\boldsymbol{\eta}}\ ^2$	$n - p$	$(2) = \frac{\ \mathbf{Y} - \hat{\boldsymbol{\eta}}\ ^2}{n-p}$	$(1)/(2)$	
Tot. Cor.	$\ \mathbf{Y}\ ^2 - n(\bar{\mathbf{Y}})^2$	$n - 1$			

Cuadro 1: Tabla de ANOVA

## Datos de Biomasa

Producción de biomasa en el estuario de Cape Fear: los datos corresponden a un estudio de la Universidad de North Carolina en el que se muestrearon 3 tipos de vegetación en tres localidades. En cada una se muestreó al azar 5 lugares con un total de 45 observaciones. Analizaremos las variables del sustrato:

$x_1$ =SAL: Salinidad

$x_2$ =pH: Acidez

$x_3$ = K: Potasio

$x_4$ =Naa: Sodio

$x_5$ =Zn: Zinc

$y$ : Biomasa Aérea

En esta etapa nos concentraremos en identificar aquellas variables que muestran mayor relación con  $y$ . Ajustaremos el modelo

$$E(y) = \beta_0 + \beta_1 SAL + \beta_2 pH + \beta_3 K + \beta_4 Naa + \beta_5 Zn$$

SALIDA DE S-PLUS

DATOS DE BIOMASA

```
> sal.lm
```

Call:

```
lm(formula = BIO ~ ., data = bio)
```

Coefficients:

(Intercept)	K	NAA	PH	SAL	ZN
1252.589	-0.2853166	-0.008662343	305.4821	-30.28808	-20.67844

Degrees of freedom: 45 total; 39 residual

Residual standard error: 398.2671

```
> summary(sal.lm)
```

Call: lm(formula = BIO ~ ., data = bio)

Residuals:

Min	1Q	Median	3Q	Max
-748.1	-223.7	-85.22	139.1	1072

Coefficients:

	Value	Std. Error	t value	Pr(> t )
(Intercept)	1252.5895	1234.7294	1.0145	0.3166
K	-0.2853	0.3483	-0.8191	0.4177
NAA	-0.0087	0.0159	-0.5438	0.5897
PH	305.4821	87.8831	3.4760	0.0013
SAL	-30.2881	24.0298	-1.2604	0.2150
ZN	-20.6784	15.0544	-1.3736	0.1774

Residual standard error: 398.3 on 39 degrees of freedom

Multiple R-Squared: 0.6773

F-statistic: 16.37 on 5 and 39 degrees of freedom, the p-value is 1.082e-008

Correlation of Coefficients:

	(Intercept)	K	NAA	PH	SAL
K	-0.3122				
NAA	0.3767	-0.8103			
PH	-0.8406	0.1212	-0.2442		
SAL	-0.9180	0.3047	-0.4324	0.6045	
ZN	-0.8809	0.1908	-0.3386	0.8350	0.7113

SALIDA DE SX

PREDICTOR VARIABLES	COEFFICIENT	STD ERROR	STUDENT'S T	P	VIF
CONSTANT	1252.59	1234.73	1.01	0.3166	
K	-0.28532	0.34832	-0.82	0.4177	3.0
NAA	-0.00866	0.01593	-0.54	0.5897	3.3
PH	305.482	87.8831	3.48	0.0013	3.3
SAL	-30.2881	24.0298	-1.26	0.2150	2.2
ZN	-20.6784	15.0544	-1.37	0.1774	4.3

R-SQUARED 0.6773 RESID. MEAN SQUARE (MSE) 158617  
 ADJUSTED R-SQUARED 0.6360 STANDARD DEVIATION 398.267

SOURCE	DF	SS	MS	F	P
REGRESSION	5	1.298E+07	2596983	16.37	0.0000
RESIDUAL	39	6186050	158617		
TOTAL	44	1.917E+07			

CASES INCLUDED 45 MISSING CASES 0

## Hipótesis Anidadas

La interpretación del test de F en términos de las hipótesis anidadas.

Supongamos que tenemos  $H_1, H_2, \dots, H_k$  un conjunto de hipótesis que imponen  $q_1, q_2, \dots, q_k$  restricciones independientes, respectivamente. Luego, las  $q_1 + q_2 + \dots + q_k$  funciones estimables son I.i. La secuencia de hipótesis anidadas estará dada por

$$\Omega, \omega_1 = \Omega \cap H_1, \omega_2 = \Omega \cap H_1 \cap H_2, \dots, \omega_k = \Omega \cap H_1 \cap H_2 \dots \cap H_k$$

Si llamamos  $\mathcal{V}^{(j)}$  a los espacios asociados cada uno de dimensión  $r - q_1 - q_2 - \dots - q_j$

$$\mathcal{V}^{(r)} \supset \mathcal{V}^{(r-q_1)} \supset \dots \mathcal{V}^{(r-q_1-q_2-\dots-q_k)}$$

Sea  $\hat{\eta}_{\omega_j}$  la proyección ortogonal de  $Y$  sobre  $\mathcal{V}^{(j)}$ , por lo tanto tenemos que

$$Y = Y - \hat{\eta} + \hat{\eta} - \hat{\eta}_{\omega_1} + \hat{\eta}_{\omega_1} - \hat{\eta}_{\omega_2} + \dots + \hat{\eta}_{\omega_{k-1}} - \hat{\eta}_{\omega_k} + \hat{\eta}_{\omega_k}$$

y en consecuencia

$$\|Y\|^2 = \|Y - \hat{\boldsymbol{\eta}}\|^2 + \|\hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_{\omega_1}\|^2 + \|\hat{\boldsymbol{\eta}}_{\omega_1} - \hat{\boldsymbol{\eta}}_{\omega_2}\|^2 + \dots + \|\hat{\boldsymbol{\eta}}_{\omega_{k-1}} - \hat{\boldsymbol{\eta}}_{\omega_k}\|^2 + \|\hat{\boldsymbol{\eta}}_{\omega_k}\|^2$$

donde cada suma tiene una distribución  $\chi^2$  no central bajo  $\Omega$  con  $n-r$ ,  $q_1$ ,  $q_2$ ,  $\dots$ ,  $q_k$ ,  $r - q_1 - q_2 - \dots - q_k$  grados de libertad.

## Intervalos Simultáneos y Regiones de Confianza

### Método de Bonferroni

Queremos hallar intervalos de confianza para  $q$  combinaciones lineales de la forma  $\mathbf{c}'\boldsymbol{\beta}$   $i = 1, 2, \dots, q$ .

Bajo normalidad, para cada combinación lineal el intervalo de la forma

$$\mathbf{c}'\hat{\boldsymbol{\beta}} \pm t_{n-r, \delta/2} \hat{\sigma} \mathbf{c}'\hat{\boldsymbol{\beta}}$$

tiene nivel  $1 - \delta$ .

Definamos los eventos

$$E_i : \mathbf{c}'\boldsymbol{\beta} \text{ pertenece al intervalo } i$$

tenemos que  $P(E_i) = 1 - \delta$

Luego,

$$1 - \alpha = P(\text{todos los intervalos son correctos}) = P(\cap_{i=1}^q E_i)$$

$$\begin{aligned} &= 1 - P((\cap_{i=1}^q E_i)^c) = 1 - P(\cup_{i=1}^q E_i^c) \\ &\geq 1 - \sum_{i=1}^q P(E_i^c) = 1 - q\delta \end{aligned}$$

Así, por ejemplo si cada intervalo tiene nivel 0.95 ( $\delta = 0.05$ ) y  $q = 10$  tendríamos que

$$1 - \alpha \geq 1 - q\delta = 1 - 10 * 0.05 = 0.50$$

¿ Cómo podríamos mejorar esto?

Si cada  $\delta = \frac{\alpha}{q}$ , entonces preservaríamos un nivel global superior a  $1 - \alpha$ .

Una clara desventaja de este método es que si  $q$  es grande al exigir que cada intervalo tenga nivel  $1 - \frac{\alpha}{q}$ , podemos obtener intervalos muy anchos y por lo tanto, de escaso valor práctico.

## Método de Scheffé

Supondremos s.p.g. que  $\mathbf{c}_1, \mathbf{c}_2, \dots, \mathbf{c}_q$  son l.i. Sea  $\Psi = \mathbf{C}\boldsymbol{\beta}$ , donde  $\mathbf{C} \in \mathbb{R}^{q \times p}$ . Inicialmente supondremos que  $\text{rg}(\mathbf{X}) = p$ . En este caso, sabemos que

$$\frac{(\widehat{\Psi} - \Psi)'(\mathbf{C}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{C}')^{-1}(\widehat{\Psi} - \Psi)}{qs^2} \sim \mathcal{F}_{q,n-p}$$

entonces

$$\begin{aligned} 1 - \alpha &= P(\mathcal{F}_{q,n-p} \leq F_{q,n-p,\alpha}) \\ &= P((\widehat{\Psi} - \Psi)'(\mathbf{C}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{C}')^{-1}(\widehat{\Psi} - \Psi) \leq qs^2 F_{q,n-p,\alpha}) \\ &= P((\widehat{\Psi} - \Psi)'\mathbf{L}^{-1}(\widehat{\Psi} - \Psi) \leq m) \\ &= P(\mathbf{b}'\mathbf{L}^{-1}\mathbf{b} \leq m) \end{aligned}$$

Recordemos que dada  $\mathbf{L}$  una matriz definida positiva tenemos que

$$\sup_{\mathbf{h} \neq \mathbf{0}} \frac{(\mathbf{h}'\mathbf{b})^2}{\mathbf{h}'\mathbf{L}\mathbf{h}} = \mathbf{b}'\mathbf{L}^{-1}\mathbf{b}$$

con lo cual, tenemos

$$\begin{aligned} 1 - \alpha &= P \left( \sup_{\mathbf{h} \neq \mathbf{0}} \frac{(\mathbf{h}'\mathbf{b})^2}{\mathbf{h}'\mathbf{L}\mathbf{h}} \leq m \right) \\ &= P \left( \frac{(\mathbf{h}'\mathbf{b})^2}{\mathbf{h}'\mathbf{L}\mathbf{h}} \leq m \quad \forall \mathbf{h} \neq \mathbf{0} \right) \\ &= P \left( \frac{|\mathbf{h}'\widehat{\Psi} - \mathbf{h}'\Psi|}{s(\mathbf{h}'\mathbf{L}\mathbf{h})^{1/2}} \leq \sqrt{qF_{q,n-p,\alpha}} \quad \forall \mathbf{h} \neq \mathbf{0} \right) \\ &= P \left( |\mathbf{h}'\widehat{\Psi} - \mathbf{h}'\Psi| \leq \sqrt{qF_{q,n-p,\alpha}} s(\mathbf{h}'\mathbf{L}\mathbf{h})^{1/2} \quad \forall \mathbf{h} \neq \mathbf{0} \right) \end{aligned}$$

Luego, para cualquier función lineal  $\mathbf{h}'\Psi$  tenemos el intervalo de confianza

$$\mathbf{h}'\widehat{\Psi} \pm \sqrt{qF_{q,n-p,\alpha}} s(\mathbf{h}'\mathbf{L}\mathbf{h})^{1/2}$$

siendo la probabilidad total de la clase  $1 - \alpha$ .

Supongamos que  $r = p$  y  $\mathbf{C} = I_p$ , en ese caso tendríamos

$$(\widehat{\boldsymbol{\beta}} - \boldsymbol{\beta})'(\mathbf{X}'\mathbf{X})(\widehat{\boldsymbol{\beta}} - \boldsymbol{\beta}) \leq ps^2F_{p,n-p,\alpha}$$

que define lo que se conoce como el elipsoide de confianza.

## ¿Cómo es en el caso general en el que $\text{rg}(\mathbf{X}) = r$ ?

Tenemos que  $\mathbf{c}'_1\boldsymbol{\beta}, \mathbf{c}'_2\boldsymbol{\beta}, \dots, \mathbf{c}'_q\boldsymbol{\beta}$  son l.i. Sea  $\Psi = \mathbf{C}\boldsymbol{\beta}$ , donde  $\mathbf{C} \in \mathbb{R}^{q \times p}$ ,  $\text{rg}(\mathbf{C}) = q$ .

Recordemos que

$$\frac{(\widehat{\Psi} - \Psi)' \mathbf{B}^{-1} (\widehat{\Psi} - \Psi)}{qs^2} \sim \mathcal{F}_{q, n-r}$$

donde  $\widehat{\Psi} \sim N(\Psi, \Sigma_{\widehat{\Psi}})$ ,  $\Sigma_{\widehat{\Psi}} = \sigma^2 \mathbf{B} = \sigma^2 \mathbf{A}^* \mathbf{A}^*$ .

Como  $\text{rg}(\mathbf{C}) = q$ , entonces  $\mathbf{B}$  tiene inversa, por lo tanto

$$\begin{aligned} 1 - \alpha &= P((\widehat{\Psi} - \Psi)' \mathbf{B}^{-1} (\widehat{\Psi} - \Psi) \leq qs^2 F_{q, n-r, \alpha}) \\ &= P((\widehat{\Psi} - \Psi)' \mathbf{B}^{-1} (\widehat{\Psi} - \Psi) \leq m) \\ &= P\left(\sup_{\mathbf{h} \neq \mathbf{0}} \frac{(\mathbf{h}' \mathbf{b})^2}{\mathbf{h}' \mathbf{B} \mathbf{h}} \leq m\right) \\ &= P\left(\frac{|\mathbf{h}' \widehat{\Psi} - \mathbf{h}' \Psi|}{s(\mathbf{h}' \mathbf{B} \mathbf{h})^{1/2}} \leq \sqrt{q F_{q, n-r, \alpha}} \quad \forall \mathbf{h} \neq \mathbf{0}\right) \end{aligned}$$

De esta forma,

$$\mathbf{h}'\widehat{\Psi} \pm \sqrt{qF_{q,n-r,\alpha}} s(\mathbf{h}'\mathbf{B}\mathbf{h})^{1/2}$$

resulta un intervalo de confianza para la función lineal  $\mathbf{h}'\Psi$  y la probabilidad total de la clase es  $1 - \alpha$ . Observemos que este intervalo es de la forma:

$$\mathbf{h}'\widehat{\Psi} \pm \sqrt{qF_{q,n-r,\alpha}} \widehat{\sigma}_{\mathbf{h}'\widehat{\Psi}}$$

## Volvamos al ejemplo de Biomasa

```
> cor(xx)
```

	BIO	K	NAA	PH	SAL	ZN
BIO	1.0000000	-0.20511626	-0.27206950	0.77418613	-0.10316780	-0.62440784
K	-0.2051163	1.00000000	0.79213460	0.01869352	-0.02049881	0.07396686
NAA	-0.2720695	0.79213460	1.00000000	-0.03771997	0.16226567	0.11704693
PH	0.7741861	0.01869352	-0.03771997	1.00000000	-0.05133280	-0.72216711
SAL	-0.1031678	-0.02049881	0.16226567	-0.05133280	1.00000000	-0.42083353
ZN	-0.6244078	0.07396686	0.11704693	-0.72216711	-0.42083353	1.00000000

Análisis con todas las variables: `lm(formula = BIO ~ K + NAA + PH + SAL + ZN)`

	Value	Std. Error	t value	Pr(> t )
(Intercept)	1252.5895	1234.7294	1.0145	0.3166
K	-0.2853	0.3483	-0.8191	0.4177
NAA	-0.0087	0.0159	-0.5438	0.5897
PH	305.4821	87.8831	3.4760	0.0013
SAL	-30.2881	24.0298	-1.2604	0.2150
ZN	-20.6784	15.0544	-1.3736	0.1774

Residual standard error: 398.3 on 39 degrees of freedom

Multiple R-Squared: 0.6773

F-statistic: 16.37 on 5 and 39 degrees of freedom, the p-value is 1.082e-008

lm(formula = BIO ~ K + PH + SAL + ZN)

	Value	Std. Error	t value	Pr(> t )
(Intercept)	1505.4479	1133.6647	1.3279	0.1917
K	-0.4388	0.2023	-2.1688	0.0361
PH	293.8169	84.4685	3.4784	0.0012
SAL	-35.9374	21.4758	-1.6734	0.1021
ZN	-23.4497	14.0396	-1.6703	0.1027

Residual standard error: 394.7 on 40 degrees of freedom

Multiple R-Squared: 0.6749

F-statistic: 20.76 on 4 and 40 degrees of freedom, the p-value is 2.525e-009

lm(formula = BIO ~ K + PH + SAL)

	Value	Std. Error	t value	Pr(> t )
(Intercept)	-131.1184	582.5120	-0.2251	0.8230
K	-0.4900	0.2043	-2.3985	0.0211
PH	410.1454	48.8253	8.4003	0.0000
SAL	-12.0533	16.3687	-0.7364	0.4657

Residual standard error: 403.3 on 41 degrees of freedom

Multiple R-Squared: 0.6522

F-statistic: 25.63 on 3 and 41 degrees of freedom, the p-value is 1.682e-009

```
lm(formula = BIO ~ K + PH)
```

	Value	Std. Error	t value	Pr(> t )
(Intercept)	-506.7131	279.8016	-1.8110	0.0773
K	-0.4871	0.2031	-2.3977	0.0210
PH	411.9779	48.4954	8.4952	0.0000

Residual standard error: 401.1 on 42 degrees of freedom

Multiple R-Squared: 0.6476

F-statistic: 38.59 on 2 and 42 degrees of freedom, the p-value is 3.074e-010

Los intervalos de confianza de nivel individual 95 % obtenidos a partir del último modelo ajustado serían tal como vimos de la forma

$$\hat{\beta}_i \pm t_{42,0.025} \hat{\sigma}_{\hat{\beta}_i} \quad \text{siendo } t_{42,0.025} = 2.018$$

En este caso resultan:

$$-1.072 < \beta_0 < 58$$

$$314 < \beta_{PH} < 510$$

$$-0.898 < \beta_K < -0.077$$

Si los calculamos con el método de Bonferroni como para que el nivel global resulte 95 % usaríamos  $t_{42,0.025/3} = 2.50$  y estos resultan

$$-1.206 < \beta_0 < 192$$

$$291 < \beta_{PH} < 533$$

$$-0.995 < \beta_K < 0.021$$

La región de confianza obtenida a partir de método de Scheffé sería

Joint Confidence  
Region

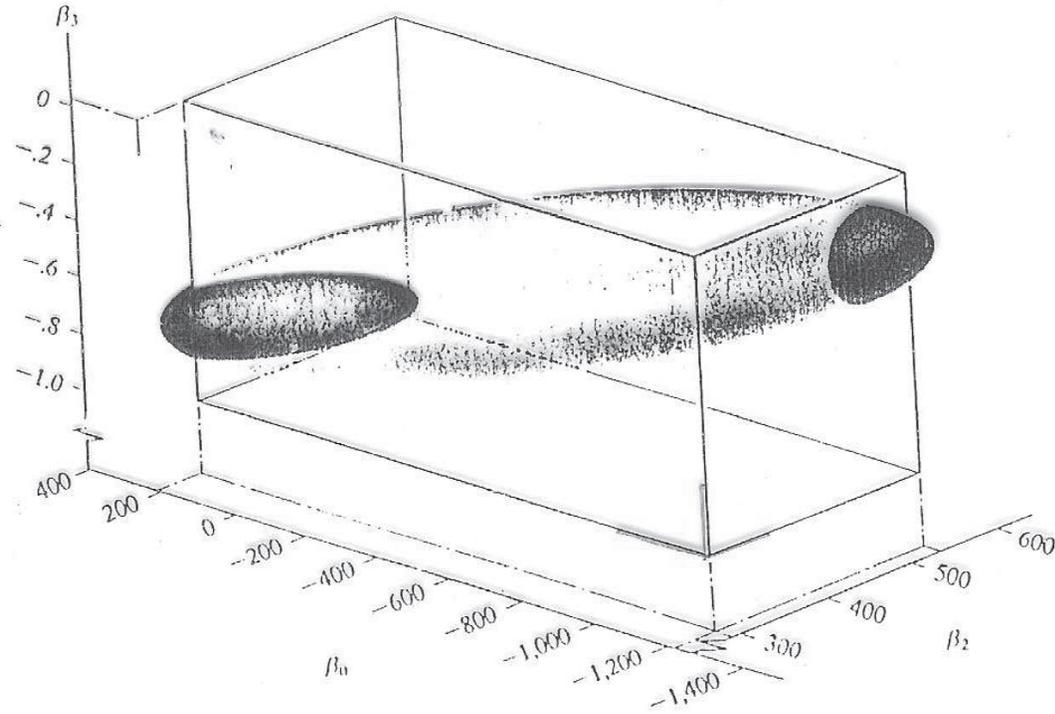


Figure 5.1 Three-dimensional 95% joint confidence region for  $\beta_0$ ,  $\beta_2$ , and  $\beta_3$ . The intersection of the Bonferroni confidence intervals is shown as the box.

## Comparación entre los métodos

Se puede ver que si las  $q$  combinaciones son l.i. entonces

$$t_{\nu, \frac{\alpha}{2q}} < \sqrt{qF_{q, \nu, \alpha}}$$

Por ejemplo, si  $\alpha = 0,05$ ,  $q = 5$  y  $n = 26$ , entonces

$$\sqrt{qF_{q, \nu, \alpha}} = 3,68 \quad t_{\nu, \frac{\alpha}{2q}} = 2,85$$

En general, si se quieren realizar intervalos simultáneos para  $k$  funciones paramétricas de las cuales  $q$  son l.i., para  $\alpha = 0,05$  se puede ver que si  $q \leq k$  y  $k$  no mucho mas grande que  $q$ , entonces

$$t_{\nu, \frac{\alpha}{2k}} < \sqrt{qF_{q, \nu, \alpha}}$$

Cuando  $k$  es mucho más grande que  $q$ , entonces la desigualdad se invierte.

## Relación entre el tests de $F$ y el método de Scheffé

Los intervalos

$$\mathbf{h}'\widehat{\Psi} \pm \sqrt{qF_{q,n-r,\alpha}} s(\mathbf{hBh})^{1/2} \quad (*)$$

y el test de  $F$  para chequear  $H : \Psi = \delta$  están relacionados.

El test de  $F$  **no** es significativo al nivel  $\alpha$  si y sólo si

$$\frac{(\widehat{\Psi} - \delta)' \mathbf{B}^{-1} (\widehat{\Psi} - \delta)}{qs^2} \leq F_{q,n-r,\alpha}$$

que es cierto si y sólo si  $\Psi = \delta$  está en la región  $(\widehat{\Psi} - \Psi)' \mathbf{B}^{-1} (\widehat{\Psi} - \Psi) \leq m$ , o sea si y sólo si  $\mathbf{h}'\delta$  está contenido en  $(*)$ .

Dicho de otra forma,  $F$  es significativo si uno o más intervalos  $(*)$  no contienen a  $\mathbf{h}'\delta$ , el problema es identificar cuál de las combinaciones lineales es la que no está contenida.

## Coeficiente de Correlación Múltiple ( o coeficiente de determinación)

Supongamos que tenemos el modelo

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_{p-1} x_{ip-1} + \epsilon_i$$

y nos interesa testear

$$H : \beta_1 = \dots = \beta_{p-1} = 0$$

Consideremos  $\Omega$  y  $\omega = \Omega \cap H$ . Llamaremos  $\hat{\eta}$  a la proyección de  $Y$  sobre el subespacio asociado a  $\Omega$  y  $\hat{\eta}_\omega$  a la proyección sobre el subespacio asociado a  $\omega$ .

¿Cuál es la correlación muestral entre el vector de observaciones  $Y$  y el vector de predichos  $\hat{Y}$  (o  $\hat{\eta}$ ) ?

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

Recordemos que cuando hay ordenada al origen, tenemos que

$$\frac{\partial}{\partial \beta_0} \|\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}\|^2 = \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_{p-1} x_{ip-1})) = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = 0$$

entonces

$$\bar{\hat{y}} = \bar{y}$$

y en consecuencia

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

Visto en términos de proyecciones y productos internos, tendríamos

$$R = \frac{\langle \mathbf{Y} - \hat{\boldsymbol{\eta}}_\omega, \hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_\omega \rangle}{\|\mathbf{Y} - \hat{\boldsymbol{\eta}}_\omega\| \|\hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_\omega\|}$$

Como

$$\begin{aligned} \langle \mathbf{Y} - \hat{\boldsymbol{\eta}}_\omega, \hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_\omega \rangle &= \langle \mathbf{Y} - \hat{\boldsymbol{\eta}}, \hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_\omega \rangle + \langle \hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_\omega, \hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_\omega \rangle \\ &= \|\hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_\omega\|^2 \end{aligned}$$

obtenemos que

$$\begin{aligned} R^2 &= \frac{\|\hat{\boldsymbol{\eta}} - \hat{\boldsymbol{\eta}}_w\|^2}{\|Y - \hat{\boldsymbol{\eta}}_w\|^2} \\ &= \frac{\text{Suma Cuadrados Total Regresión}}{\text{Suma Cuadrados Total Corregida}} \end{aligned}$$

es decir

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

La relación entre el estadístico F y el coeficiente de correlación múltiple está dada por el siguiente resultado

**Teorema:** Supongamos que deseamos testear  $H : \mathbf{C}\boldsymbol{\beta} = \mathbf{0}$ , que no involucra al intercept  $\beta_0$ , es decir  $\mathbf{C}$  es de la forma  $[0, \mathbf{C}_1]$ . Consideremos  $\omega_1 = \Omega \cap H$ . Sea

$$R_{\omega_1}^2 = \frac{\sum_{i=1}^n (\hat{y}_{i\omega_1} - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

entonces el estadístico  $F$  para testear  $H$  será

$$F = \frac{(R^2 - R_{\omega_1}^2)(n - p)}{(1 - R^2)q}$$

Como corolario de este teorema obtenemos que  $R^2 - R_{\omega_1}^2 \geq 0$  pues  $F \geq 0$  y por lo tanto, el coeficiente de correlación múltiple o de determinación  $R^2$  nunca decrece al agregar una variable regresora extra.

Esta es una deventaja de  $R^2$  si uno lo quiere usar para comparar el ajuste de modelos de distinto número de covariables, y por esta razón se suele utilizar el coeficiente de determinación ajustado definido por

$$R_{adj}^2 = 1 - (1 - R^2) \frac{n}{n - p}$$

que no crece necesariamente con  $p$  y de hecho se puede demostrar que  $R_{adj}^2$  aumenta al agregar una covariable sólo si el estadístico  $F$  que testea que los parámetros agregados son 0 es mayor a 1.