

Modelos Lineales Generalizados: aplicaciones en R

Modelos Lineales Generalizados: un enfoque aplicado

Ana M. Bianco Jemina García

(anambianco@gmail.com) (jeminagarcia@gmail.com)

1. Modelo Lineal

Modelización y Predicción

Algunos de los métodos estadísticos más extendidos se ocupan de la modelización de datos y de la predicción.

Muchas de estas técnicas estadísticas se encuadran en lo que hoy se conoce como **aprendizaje estadístico** (AE).

El AE abarca una vasta cantidad de procedimientos que ayudan a comprender los datos cuando se analizan varias variables al mismo tiempo, ya sea postulando modelos o encontrando relaciones entre las variables o estructuras que ayudan a su comprensión.

Modelización y Predicción


Los métodos de AE pueden reunirse en dos grandes grupos:

- ▶ **Aprendizaje Supervisado:** Aquí una de las variables es identificada como una respuesta
- ▶ **Aprendizaje No Supervisado:** todas las variables cumplen un rol análogo.

El modelo lineal puede pensarse como la aproximación simple al aprendizaje supervisado.

Un modelo muy difundido de ajuste y predicción, que puede verse como es un caso particular de GLM.

Modelo Lineal: aproximación



En general, la verdadera relación es más compleja!!

Aprendizaje Estadístico

Algunos ejemplos:

- ▶ Predecir si un paciente hospitalizado tendrá un segundo infarto de miocardio o no teniendo en cuenta mediciones clínicas, dietas y variables demográficas.
- ▶ Predecir los precios que tendrán en 6 meses las acciones de ciertas compañías a partir de mediciones del rendimiento de las compañías y datos económicos.
- ▶ Estimar la cantidad de glucosa en sangre que tendrá un individuo diabético a partir del espectro de adsorción infra-rojo de la sangre.
- ▶ Identificar los factores de riesgo de cáncer de próstata, usando mediciones clínicas y variables demográficas.

Ganancia de un transistor

En un estudio se miden y = ganancia de un transistor en un circuito integrado entre el emisor y el receptor (hFE) junto con dos variables que pueden ser controladas. Se realizaron 14 mediciones.

- ▶ x_1 = tiempo de conducción en minutos
- ▶ x_2 = iones $\times 10^{14}$


Ganancia de un transistor

```
> iones<- read.table("iones.txt",header=T)
> iones<- iones[,2:4]
> attach(iones)
> iones
```

	x1	x2	y
1	195	4.00	1004
2	255	4.00	1636
3	195	4.60	852
4	255	4.60	1506
5	225	4.20	1272
6	225	4.10	1270
7	225	4.60	1269
8	195	4.30	903
9	255	4.30	1555
10	225	4.00	1260
11	225	4.70	1146
12	225	4.30	1276
13	225	4.72	1225
14	230	4.30	1321

Ganancia de un transistor

```
> pairs(iones, col="blue")
```



Datos de Prostata

En 97 pacientes que van a tener una prostatectomía radical se miden las siguientes variables:

- ▶ $x_1 = \mathbf{lcavol}$: log del volumen del tumor
- ▶ $x_2 = \mathbf{lweight}$: log del peso de la próstata
- ▶ $x_3 = \mathbf{age}$: edad
- ▶ $x_4 = \mathbf{lbph}$: log de la cantidad de hiperplasia prostática benigna
- ▶ $x_5 = \mathbf{svi}$: invasión seminal (si o no)
- ▶ $x_6 = \mathbf{lcp}$: logaritmo de la penetración capsular
- ▶ $x_7 = \mathbf{gleason}$: score de Gleason
- ▶ $x_8 = \mathbf{pgg46}$: porcentaje de scores de Gleason 4 or 5.
- ▶ $x_9 = \mathbf{lpsa}$: log del PSA (PSA: Antígeno prostático)


El objetivo es predecir el log del PSA.

Datos de Prostata: Diagramas de Dispersión


```
> setwd("C:\\Users\\Ana\\Dropbox\\Ana\\GLM\\2019\\Doctex")
> datos.ori<- read.table("prostate.txt",header=T)
> datos<- datos.ori[,1:9]
> attach(datos)
> print(datos[1:6,],digits=3)
```

	lcavol	lweight	age	lbph	svi	lcp	gleason	pgg45	lpsa
1	-0.580	2.77	50	-1.39	0	-1.39	6	0	-0.431
2	-0.994	3.32	58	-1.39	0	-1.39	6	0	-0.163
3	-0.511	2.69	74	-1.39	0	-1.39	7	20	-0.163
4	-1.204	3.28	58	-1.39	0	-1.39	6	0	-0.163
5	0.751	3.43	62	-1.39	0	-1.39	6	0	0.372
6	-1.050	3.23	50	-1.39	0	-1.39	6	0	0.765

```
> pairs(datos, col="blue")
```



```
> plot(lcavol, lpsa, col="blue")
```



Modelo Lineal Simple

En regresión lineal interesa establecer la relación entre una variable dependiente y y otras p variables: x_1, \dots, x_p explicativas.

El caso más sencillo es cuando tenemos una sola variable explicativa:

$$y = \beta_0 + \beta_1 x + \epsilon$$

donde

- ▶ β_0 : ordenada al origen o intercept
- ▶ β_1 : pendiente
- ▶ ϵ : error

Modelo Lineal Simple

En regresión lineal interesa establecer la relación entre una variable dependiente y y otras p variables: x_1, \dots, x_p explicativas.

El caso más sencillo es cuando tenemos una sola variable explicativa:

$$y = \beta_0 + \beta_1 x + \epsilon$$

donde

- ▶ β_0 : ordenada al origen o intercept
- ▶ β_1 : pendiente
- ▶ ϵ : error

El modelo es lineal en los parámetros β_0 y β_1 . De manera que

$$y = \beta_0 + \beta_1 x^2 + \epsilon$$

también es un modelo lineal.

Modelo Lineal Simple

β_0, β_1 son 2 parámetros desconocidos a estimar.

Para ello suponemos que disponemos de una muestra $(y_1, x_1), \dots, (y_n, x_n)$ independientes tales que

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i \quad i = 1, \dots, n$$

donde

- ▶ $E(\epsilon) = 0$
- ▶ $V(\epsilon) = \sigma^2$
- ▶ ϵ_i son no correlacionados: $Cov(\epsilon_i, \epsilon_j) = 0$ si $i \neq j$

¿Cómo estimamos los parámetros?


Mínimos Cuadrados


Si los puntos en un gráfico parecen seguir una recta, el problema es elegir la recta que mejor ajusta los puntos.


Tendremos en cuenta:

- a) tomar una distancia promedio de la recta a todos los puntos
- b) mover la recta hasta que esta distancia promedio sea la menor posible.

Si tenemos (y_i, x_i) , $1 \leq i \leq n$, y, en forma genérica, queremos predecir la respuesta y a partir de la covariable x usando una recta, podríamos definir el error cometido en cada punto como la distancia vertical del punto a la recta.







Estimadores de mínimos cuadrados

$$\min_{b_0, b_1} \sum_{i=1}^n (y_i - (b_0 + b_1 x_i))^2$$

Si definimos

$$\mathcal{S}(b_0, b_1) = \sum_{i=1}^n (y_i - (b_0 + b_1 x_i))^2$$

para hallar el mínimo debemos derivar e igualar a 0:

$$\frac{\partial \mathcal{S}}{\partial b_0}(b_0, b_1) = -2 \sum_{i=1}^n (y_i - (b_0 + b_1 x_i)) = 0$$

$$\frac{\partial \mathcal{S}}{\partial b_1}(b_0, b_1) = -2 \sum_{i=1}^n (y_i - (b_0 + b_1 x_i)) x_i = 0$$

Estimadores de mínimos cuadrados

$$\min_{b_0, b_1} \sum_{i=1}^n (y_i - (b_0 + b_1 x_i))^2$$

Si definimos

$$S(b_0, b_1) = \sum_{i=1}^n (y_i - (b_0 + b_1 x_i))^2$$

Desarrollando quedan las **ecuaciones normales**

$$\begin{aligned} n\hat{\beta}_0 + \left(\sum_{i=1}^n x_i \right) \hat{\beta}_1 &= \sum_{i=1}^n y_i \\ \left(\sum_{i=1}^n x_i \right) \hat{\beta}_0 + \left(\sum_{i=1}^n x_i^2 \right) \hat{\beta}_1 &= \sum_{i=1}^n y_i x_i \end{aligned}$$

Estimadores de mínimos cuadrados

Entonces

$$\begin{aligned}\hat{\beta}_0 &= \bar{y} - \bar{x}\hat{\beta}_1 \\ \hat{\beta}_1 &= \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}\end{aligned}$$

Notacion Matricial

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i \quad 1 \leq i \leq n$$

$$y_1 = \beta_0 + \beta_1 x_1 + \epsilon_1$$

$$y_2 = \beta_0 + \beta_1 x_2 + \epsilon_2$$

...

$$y_n = \beta_0 + \beta_1 x_n + \epsilon_n$$

$$\begin{pmatrix} y_1 \\ y_2 \\ \cdot \\ \cdot \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \cdot & \cdot \\ \cdot & \cdot \\ 1 & x_n \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \cdot \\ \cdot \\ \epsilon_n \end{pmatrix}$$

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

Notacion Matricial

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i \quad 1 \leq i \leq n$$

$$\mathbf{Y} = \begin{pmatrix} y_1 \\ y_2 \\ \cdot \\ \cdot \\ y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \cdot & \cdot \\ \cdot & \cdot \\ 1 & x_n \end{pmatrix} \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix} \quad \boldsymbol{\epsilon} = \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \cdot \\ \cdot \\ \epsilon_n \end{pmatrix}$$

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

Ecuaciones Normales

Las 2 ecuaciones normales pueden escribirse como

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

Cuando $\mathbf{X}'\mathbf{X}$ es no singular, la solución es única y resulta

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

Para tener en cuenta...

En el caso de regresión simple tendríamos

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ x_1 & x_2 & x_3 & \dots & x_n \end{pmatrix} \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \cdot & \cdot \\ \cdot & \cdot \\ 1 & x_n \end{pmatrix}$$

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

El sistema sería

$$\begin{pmatrix} n & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix} \begin{pmatrix} b_0 \\ b_1 \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_i y_i \end{pmatrix}$$

Para tener en cuenta...

La inversa resulta

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

y además

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

y por lo tanto

$$\hat{\boldsymbol{\beta}} = \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{pmatrix} = \frac{1}{n \sum_{i=1}^n (x_i - \bar{x})^2} \begin{pmatrix} (\sum_{i=1}^n y_i)(\sum_{i=1}^n x_i^2) - (\sum_{i=1}^n x_i)(\sum_{i=1}^n x_i y_i) \\ n \sum_{i=1}^n x_i y_i - (\sum_{i=1}^n y_i)(\sum_{i=1}^n x_i) \end{pmatrix}$$

Datos de Prostata: lcvol vs. lpsa

```
> salida<- lm(lpsa~lcvol)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	-0.50858	0.19419	-2.619	0.0103	*
lpsa	0.74992	0.07109	10.548	<2e-16	***

NA

Residual standard error: 0.8041 on 95 degrees of freedom

Multiple R-squared: 0.5394, Adjusted R-squared: 0.5346

F-statistic: 111.3 on 1 and 95 DF, p-value: < 2.2e-16


Datos de Prostata: lpsa vs. lcavol

```
> salida$coefficients
```

```
(Intercept)      lcavol  
  1.5072975    0.7193204
```



```
> plot(lcavol,lpsa,col="blue")
```

```
> abline(lm(lpsa~lcavol),col="red")
```



Datos de Prostata: lcavol vs. lpsa

- > `par(mfrow=c(1,2))`
- > `plot(lcavol,lpsa,col="blue")`
- > `abline(lm(lpsa~lcavol),col="red")`
- > `plot(salida$fitted.values,salida$residuals)`
- > `abline(h=0,col="red")`



Predichos y Residuos

- i-ésimo valor predicho $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$
- i-ésimo residuo $r_i = y_i - \hat{y}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i)$

Explicando la Variabilidad

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

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

Sumas de cuadrados

Explicando la Variabilidad

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





Puede escribir como $SCT = SCE + SCR$ donde

- ▶ $SCT = \sum_{i=1}^n (y_i - \bar{y})^2$ variabilidad total: variabilidad total de la respuesta \mathbf{Y}
- ▶ $SCE = \sum_{i=1}^n r_i^2$ variabilidad residual: variabilidad de \mathbf{Y} no explicada por el modelo de regresión.
- ▶ $SCR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$ variabilidad de la regresión: variabilidad de \mathbf{Y} explicada por el modelo de regresión

Coeficiente R^2

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

- ▶ $0 \leq R^2 \leq 1$
- ▶ Es la proporción de variación explicada por la regresión
- ▶ $R^2 \approx 1 \Rightarrow$ el modelo explica muy bien
- ▶ $R^2 \approx 0 \Rightarrow$ el modelo provee un ajuste pobre



Caso de más covariables

La notación matricial es muy adecuada para tratar el caso más general.

respuesta $y \longleftrightarrow p$ variables explicativas x_j

Supondremos $x_j, 1 \leq j \leq p$ son determinísticas.

Muestra $(x_{i1}, \dots, x_{ip}, y_i), 1 \leq i \leq n$ que cumplen el modelo

$$\begin{aligned}y_i &= \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \epsilon_i \quad i = 1, \dots, n \\E(\epsilon_i) &= 0 \\V(\epsilon_i) &= \sigma^2 \\cov(\epsilon_i, \epsilon_j) &= 0 \quad i \neq j\end{aligned}$$

donde, $\beta_0, \beta_1, \dots, \beta_p$ son $p + 1$ parámetros desconocidos a estimar

Caso general

$$y_1 = \beta_0 + \beta_1 x_{11} + \cdots + \beta_p x_{1p} + \epsilon_1$$

$$y_2 = \beta_0 + \beta_1 x_{21} + \cdots + \beta_p x_{2p} + \epsilon_2$$

...

$$y_n = \beta_0 + \beta_1 x_{n1} + \cdots + \beta_p x_{np} + \epsilon_n$$

El estimador de mínimos cuadrados de $\beta_0, \beta_1 \dots \beta_p$ minimiza

$$S(b_0, b_1, \dots, b_p) = \sum_{i=1}^n (y_i - (b_0 + b_1 x_{i1} + \cdots + b_p x_{ip}))^2$$

Caso general

$$y_1 = \beta_0 + \beta_1 x_{11} + \cdots + \beta_p x_{1p} + \epsilon_1$$

$$y_2 = \beta_0 + \beta_1 x_{21} + \cdots + \beta_p x_{2p} + \epsilon_2$$

...

$$y_n = \beta_0 + \beta_1 x_{n1} + \cdots + \beta_p x_{np} + \epsilon_n$$

$$\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1p} \\ 1 & x_{21} & x_{22} & \cdots & x_{2p} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{pmatrix}$$

↓

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

Caso general

$$y_i = \beta_0 + \beta_1 x_{i1} + \cdots + \beta_p x_{ip} + \epsilon_i \quad i = 1, \dots, n$$

En el caso general tenemos

$$\mathbf{Y} = \begin{pmatrix} y_1 \\ y_2 \\ \cdot \\ \cdot \\ y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1p} \\ 1 & x_{21} & x_{22} & \cdots & x_{2p} \\ & \cdots & & \cdots & \\ & \cdots & & \cdots & \\ 1 & x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix}$$

$$\boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \cdot \\ \cdot \\ \beta_p \end{pmatrix} \quad \boldsymbol{\epsilon} = \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \cdot \\ \cdot \\ \epsilon_n \end{pmatrix}$$

↓

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

Caso general

El estimador de mínimos cuadrados de $\beta_0, \beta_1 \dots \beta_p$ minimiza

$$S(b_0, b_1, \dots, b_p) = \sum_{i=1}^n (y_i - (b_0 + b_1 x_{i1} + \dots + b_p x_{ip}))^2$$

Derivando e igualando a 0 obtenemos las **ecuaciones normales**.

Los estimadores de mínimos cuadrados $\hat{\beta}_0, \dots, \hat{\beta}_p$ cumplen:

$$\frac{\partial S(\mathbf{b})}{\partial b_0} = -2 \sum_{i=1}^n (y_i - \mathbf{x}'_i \mathbf{b}) = 0$$

$$\frac{\partial S(\mathbf{b})}{\partial b_k} = -2 \sum_{i=1}^n (y_i - \mathbf{x}'_i \mathbf{b}) x_{ik} = 0 \quad k = 1, \dots, p$$

siendo $\mathbf{x}'_i = (1, x_{i1}, \dots, x_{ip})$ a i -ésima fila de la matriz de diseño \mathbf{X}

Ecuaciones Normales

$\hat{\beta}_0, \dots, \hat{\beta}_p$, los estimadores de mínimos cuadrados cumplen:

$$n\hat{\beta}_0 + \hat{\beta}_1 \left(\sum_{i=1}^n x_{i1} \right) + \dots + \hat{\beta}_p \left(\sum_{i=1}^n x_{ip} \right) = \sum_{i=1}^n y_i$$

$$\hat{\beta}_0 \left(\sum_{i=1}^n x_{ik} \right) + \hat{\beta}_1 \left(\sum_{i=1}^n x_{i1}x_{ik} \right) + \dots + \hat{\beta}_p \left(\sum_{i=1}^n x_{ip}x_{ik} \right) = \sum_{i=1}^n y_i x_{ik} \quad k = 1, \dots, p$$

Ecuaciones Normales

Estas $p + 1$ ecuaciones pueden escribirse como

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

que se conocen como **ecuaciones normales**

Cuando $\mathbf{X}'\mathbf{X}$ es no singular, la solución es única y resulta

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

Propiedades

Bajo los supuestos que hemos mencionado:

- $\hat{\beta}$ es insesgado: $E(\hat{\beta}) = \beta$ (sesgo)
- $V(\hat{\beta}) = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}$ (varianza)
- $\hat{\beta}$ es una combinación lineal de \mathbf{Y} (linealidad)
- $\hat{\beta}$ es el estimador lineal insesgado de menor varianza (optimalidad)

Predichos y Residuos

- i-ésimo valor predicho $\hat{y}_i = \mathbf{x}'_i \hat{\boldsymbol{\beta}} = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \cdots + \hat{\beta}_p x_{ip}$
- i-ésimo residuo $r_i = y_i - \hat{y}_i = y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \cdots + \hat{\beta}_p x_{ip})$

Explicando la Variabilidad: igual que antes...

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

Inferencia

Para hacer inferencia sobre los coeficientes del modelo (tests de hipótesis e intervalos de confianza) es necesario hacer un supuesto adicional:

Normalidad de los errores: $\epsilon_i \sim N(0, \sigma^2)$

→ **media 0, homoscedásticos e independientes**

Tradicionalmente se hacen tests de hipótesis para determinar la significación de cada uno de los coeficientes (y los IC asociados) y también se realiza un test para comprobar la significación de toda la regresión.

Inferencia individual

Para hacer inferencia, tests de hipótesis e intervalos de confianza, sobre los coeficientes del modelo es necesario hacer un supuesto adicional:

Normalidad de los errores: $\epsilon_i \sim N(0, \sigma^2)$

→ **media 0, homoscedásticos e independientes.**

Cuando \mathbf{X} tiene rango completo puede probarse que:

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

Regresión lineal simple queda:

$$\text{Var}(\hat{\beta}_0) = \sigma^2 \left(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right)$$

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

⇒ σ necesitaremos estimarla

Estimación de σ^2

Un estimador insesgado de σ^2 es

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - (p + 1)} = \frac{\sum_{i=1}^n r_i^2}{n - p - 1}$$

Bajo el supuesto $\epsilon_i \sim N(0, \sigma^2)$

$$\frac{\hat{\beta}_j - \beta_j}{\sqrt{\widehat{\text{var}}(\hat{\beta}_j)}} \sim t_{n-p-1} \quad j = 0, 1, \dots, p$$

Por lo tanto: un intervalo de nivel exacto $1 - \alpha$

$$\hat{\beta}_j \pm t_{n-p-1, \alpha/2} \sqrt{\widehat{\text{var}}(\hat{\beta}_j)}$$

Regresión Lineal Simple

Así, en el caso más simple obtendríamos los siguientes Intervalos de Confianza de nivel $1 - \alpha$

$$\hat{\beta}_0 \pm t_{n-2, \alpha/2} \hat{\sigma} \sqrt{\left(\frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right)}$$

$$\hat{\beta}_1 \pm t_{n-2, \alpha/2} \hat{\sigma} \sqrt{\frac{1}{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

Tests de Hipótesis

Bajo el supuesto $\epsilon_i \sim N(0, \sigma^2)$

$$\frac{\hat{\beta}_j - \beta_j}{\sqrt{\widehat{\text{var}}(\hat{\beta}_j)}} \sim t_{n-p-1} \quad j = 0, 1, \dots, p$$

Para testear: $H_0 : \beta_j = 0$ vs. $H_1 : \beta_j \neq 0$ basta comparar con el percentil deseado de una t_{n-p-1} a

$$\frac{\hat{\beta}_j}{\sqrt{\widehat{\text{var}}(\hat{\beta}_j)}}$$

Rechazamos H_0 a nivel α si

$$\left| \frac{\hat{\beta}_j}{\sqrt{\widehat{\text{var}}(\hat{\beta}_j)}} \right| > t_{n-p-1, \alpha/2}$$

Analizamos una salida

```
> salida.iones<-lm(y~x1+x2)
> summary(salida.iones)
```

Call:

```
lm(formula = y ~ x1 + x2)
```

Residuals:

Min	1Q	Median	3Q	Max
-44.584	-24.565	-3.266	22.330	63.201

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	-520.0767	192.1071	-2.707	0.02039	*
x1	10.7812	0.4743	22.730	1.35e-10	***
x2	-152.1489	36.6754	-4.149	0.00162	**

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 34.93 on 11 degrees of freedom

Multiple R-squared: 0.9798, Adjusted R-squared: 0.9762

F-statistic: 267.2 on 2 and 11 DF, p-value: 4.742e-10

Test de Significación de toda la regresión

Este test chequea la hipótesis

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0 \quad \text{vs.} \quad H_1 : \exists \text{ al menos un } \beta_j \neq 0$$

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

Bajo normalidad, tenemos que

$$F = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2 / p}{\sum_{i=1}^n (y_i - \hat{y}_i)^2 / (n - p - 1)} \sim \mathcal{F}_{p, n-p-1},$$

Test de Significación de toda la regresión

Este test chequea la hipótesis

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0 \quad \text{vs.} \quad H_1 : \exists \text{ al menos un } \beta_j \neq 0$$

En el ejemplo, tenemos:

F-statistic 267.2 on 2 and 11 DF, p-value 4.742 e-10

Por lo que el estadístico F concluye que el modelo de regresión es altamente significativo.

R^2 ajustado

Para completar la lectura de la salida, tenemos que introducir al R^2 ajustado.

El coeficiente R^2 tiene la particularidad de que a medida que se agregan nuevas variables, va aumentando.

Esta no es una característica deseable cuando se desean comparar modelos con distinto número de variables o complejidad. Para ello se suele usar una versión corregida que penaliza por la cantidad de parámetros del modelo:

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

R_{adj}^2 tiene en cuenta la complejidad del modelo