

# Modelo con un regresor

## Contents

1	Introducción	1
2	Ecuación del modelo	2
3	Notación matricial del modelo	3
4	Estimación del modelo usando mínimos cuadrados	4
5	Datos, modelo y residuos	4
6	Aplicacion a los datos del ejemplo	5
7	Bondad del modelo ajustado	6

## 1 Introducción

Vamos a leer el archivo de datos *kidiq.csv*:

```
d = read.csv("datos/kidiq.csv")
str(d)


## 'data.frame':  434 obs. of  5 variables:
## $ kid_score: int  65 98 85 83 115 98 69 106 102 95 ...
## $ mom_hs   : int  1 1 1 1 1 0 1 1 1 1 ...
## $ mom_iq   : num 121.1 89.4 115.4 99.4 92.7 ...
## $ mom_work : int  4 4 4 3 4 1 4 3 1 1 ...
## $ mom_age  : int  27 25 27 25 27 18 20 23 24 19 ...
```

donde se recogen datos de las siguientes variables:

- **kid\_score** : puntuacion de un test cognitivo en niños de 3-4 años
- **mom\_hs** :
  - mom\_hs = 1 : las madres han terminado secundaria (high school)
  - mom\_hs = 0 : las madres no terminaron secundaria
- **mom\_iq** : puntuación de la madre en otro test cognitivo
- **mom\_work** :
  - mom\_work = 1 : la madre no trabajó en los primeros tres años del niño
  - mom\_work = 2 : la madre trabajó en el segundo o tercer año
  - mom\_work = 3 : la madre trabajó a tiempo parcial el primer año
  - mom\_work = 4 : la madre trabajó a tiempo completo el primer año
- **mom\_age** : edad de la madre

Estamos interesados en estudiar si la puntuación obtenida por los niños (variable *kid\_score*) está relacionada con la puntuación obtenida por las madres (*mom\_iq*). Primero dibujamos el gráfico de dispersión:

```
plot(d$mom_iq, d$kid_score)
```



Como se observa, en términos generales cuando mayor es la puntuación obtenida por las madres mayor es la puntuación de los niños.

## 2 Ecuación del modelo


El modelo más sencillo que relaciona ambas variables es el modelo lineal:

$$kid\_score_i = \beta_0 + \beta_1 mom\_iq_i, \quad i = 1, 2, \dots, n$$

Es la ecuación de una recta. Sin embargo, es imposible calcular una recta que pase por todos los puntos del gráfico. Otra posibilidad es utilizar el modelo:

$$kid\_score_i = \beta_0 + \beta_1 mom\_iq_i + e_i, \quad i = 1, 2, \dots, n$$

es decir, se incluye el término  $e_i$  que modele la diferencia entre el valor observado en  $kid\_score_i$  y el valor que toma la recta en ese punto ( $\beta_0 + \beta_1 mom\_iq_i$ ).



Estos términos se denominan **residuos**, y se definen como:

$$e_i = kid\_score_i - (\beta_0 + \beta_1 mom\_iq_i), \quad i = 1, 2, \dots, n$$

### 3 Notación matricial del modelo

El modelo anterior se denomina **modelo de regresión lineal con un regresor**. De forma genérica se puede escribir así:

$$kid\_score_i = \beta_0 + \beta_1 mom\_iq_i + e_i, \quad i = 1, 2, \dots, n$$

Si escribimos la ecuación para todos los datos disponibles:

$$i = 1 \Rightarrow kid\_score_1 = \beta_0 + \beta_1 mom\_iq_1 + e_1$$

$$i = 2 \Rightarrow kid\_score_2 = \beta_0 + \beta_1 mom\_iq_2 + e_2$$

...

$$i = n \Rightarrow kid\_score_n = \beta_0 + \beta_1 mom\_iq_n + e_n$$

Agrupando:

$$\begin{bmatrix} kid\_score_1 \\ kid\_score_2 \\ \dots \\ kid\_score_n \end{bmatrix} = \begin{bmatrix} 1 & mom\_iq_1 \\ 1 & mom\_iq_2 \\ \dots & \dots \\ 1 & mom\_iq_n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \dots \\ e_n \end{bmatrix}$$

Finalmente, en notación matricial:

$$y = X\beta + e$$

donde  $\beta$  es el vector de parámetros:

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}$$

## 4 Estimación del modelo usando mínimos cuadrados

El modelo propuesto depende de dos parámetros,  $\beta_0$  y  $\beta_1$ , que son desconocidos. Existen diferentes métodos para calcular dichos parámetros, entre ellos, el método de mínimos cuadrados. Este método consiste en calcular el valor del vector  $\beta$  que minimiza la suma de los residuos al cuadrado (RSS, *residuals sum of squares*):

$$RSS = \sum e_i^2 = e^T e = (y - X\beta)^T (y - X\beta) = RSS(\beta)$$

Desarrollando el producto:

$$RSS(\beta) = y^T y - y^T X\beta - \beta^T X^T y + \beta^T X^T X\beta$$

Para calcular el mínimo se deriva respecto a  $\beta$  y se iguala a cero (ver Apendice)

$$\frac{dRSS(\beta)}{d\beta} = -X^T y - X^T y + (X^T X + X^T X)\beta = 0$$

$$\beta = (X^T X)^{-1} X^T y$$

## 5 Datos, modelo y residuos

Los datos disponibles son

$$\{kid\_score_i, mom\_iq_i\}, i = 1, \dots, n$$

Esos datos los modelamos utilizando la ecuación:

$$kid\_score_i = \beta_0 + \beta_1 mom\_iq_i + e_i, i = 1, 2, \dots, n$$

Es decir, para una madre dada  $mom\_iq_i$ , dividimos la puntuación de su hijo  $kid\_score_i$  en dos partes: la parte que corresponde a la recta  $b_0 + b_1 mom\_iq_i$  y los residuos  $e_i$ . La parte correspondiente a la recta se puede representar matricialmente como:

$$\hat{y} = X\beta$$

donde  $\hat{y} = [\hat{y}_1 \ \hat{y}_2 \ \dots \ \hat{y}_n]^T$ . Por tanto los residuos se pueden calcular como

$$e_i = y_i - \hat{y}_i, \quad i = 1, 2, \dots, n$$

o en forma matricial

$$e = y - \hat{y}$$

## 6 Aplicacion a los datos del ejemplo

- Matrices del modelo

```
y = matrix(d$kid_score, ncol = 1)
head(y)
```

```
##      [,1]
## [1,]  65
## [2,]  98
## [3,]  85
## [4,]  83
## [5,] 115
## [6,]  98
```

```
n = nrow(d)
X = cbind(rep(1,n), d$mom_iq)
head(X)
```

```
##      [,1]      [,2]
## [1,]    1 121.11753
## [2,]    1  89.36188
## [3,]    1 115.44316
## [4,]    1  99.44964
## [5,]    1  92.74571
## [6,]    1 107.90184
```

- Estimacion

```
Xt_X = t(X) %*% X
Xt_y = t(X) %*% y
( beta = solve(Xt_X) %*% Xt_y )
```


```
##      [,1]
## [1,] 25.7997778
## [2,]  0.6099746
```

- valores de la recta

```
y_e = X %*% beta
```

Estos valores se pueden representar


```
plot(d$mom_iq, d$kid_score)
points(d$mom_iq, y_e, col = "red", pch = 19)
```



Finalmente, los residuos se calculan haciendo

```
e = y - y_e
```

```
plot(d$mom_iq, e)
```



## 7 Bondad del modelo ajustado

Es conveniente medir como de bueno es el ajuste del modelo. Una posibilidad es usar la suma de los residuos al cuadrado o RSS:

```
(RSS = sum(e^2))
```

```
## [1] 144137.3
```

Pero esta variable depende de las unidades de  $x$  e  $y$ . Por tanto es difícil saber si un RSS alto indica que el modelo es bueno o malo. Lo ideal es utilizar variables adimensionales. La manera más usual es utilizar el coeficiente de determinación o  $R^2$ :

$$R^2 = 1 - \frac{RSS}{TSS}$$

donde TSS es la suma total de cuadrados

$$TSS = \sum (y_i - \bar{y})^2$$

```
(TSS = sum((y-mean(y))^2))
```

```
## [1] 180386.2
```

```
(R2 = 1 - RSS/TSS)
```

```
## [1] 0.2009512
```

El coeficiente  $R^2$  toma valores entre cero y uno.

La suma total de cuadrados de  $y$  está relacionado con su varianza, ya que

$$s_y^2 = \frac{\sum (y_i - \bar{y})^2}{n - 1} \Rightarrow TSS = (n - 1)s_y^2$$

```
(n-1)*var(y)
```

```
## [1,] 180386.2
```

```
## [1,] 180386.2
```