

Capitolo 4

Regressione Lineare con un Regressore

■ Soluzioni

1. (a) La predizione della regressione relativa al punteggio medio del test per tale classe è

$$\boxed{\text{TestScore} = 520.4 - 5.82 \times 22 = 392.36}$$

- (b) La predizione della regressione relativa alla variazione del punteggio medio del test nella classe è

$$\boxed{\Delta \text{TestScore} = (-5.82 \times 19) - (-5.82 \times 23) = 23.28}$$

- (c) L'intervallo di confidenza al 95% è $5.82 \pm (1.96 \times 2.21) = (1.4884, 10.15)$

- (d) Il valore-p di un test bilaterale per l'ipotesi nulla $H_0: \beta_1 = 0$ è

$$\text{valore-p} = \Pr(|Z| > |t^{act}|) = 2\Phi(-|t^{act}|) = 2\Phi(-2.633) = 0.0086$$

L'ipotesi nulla si rigetta sia al 5% che all'1%.

- (c) Utilizzando la formula per $\hat{\beta}_0$, sappiamo che la media campionaria del punteggio del test nelle 100 classi è

$$\overline{\text{TestScore}} = \hat{\beta}_0 + \hat{\beta}_1 \times \overline{CS} = 520.4 - 5.82 \times 21.4 = 395.85.$$

- (d) Utilizziamo la formula per l'errore standard della regressione (SER) per ottenere la somma dei quadrati residui:

$$SSR = (n - 2)SER^2 = (100 - 2) \times 11.5^2 = 12961.$$

Utilizziamo la formula di R^2 per calcolare la somma dei quadrati totale:

$$TSS = \frac{SSR}{1 - R^2} = \frac{12961}{1 - 0.08^2} = 13044.$$

La varianza del campione è $s_Y^2 = \frac{TSS}{n-1} = \frac{13044}{99} = 131.8$. Quindi la deviazione standardizzata campionaria è $s_Y = \sqrt{s_Y^2} = 11.5$.

2. (a) La differenza stimata dovuta al genere è \$2.79/hour.

- (b) La verifica d'ipotesi circa la differenza dovuta al genere è $H_0: \beta_1 = 0$ vs. $H_1: \beta_1 \neq 0$. La statistica-t è

$$t^{act} = \frac{\hat{\beta}_1 - 0}{SE(\hat{\beta}_1)} = \frac{2.79}{0.84} = 3.32,$$

il valore-p per il test è

$$\text{valore-p} = 2\Phi(-|t^{act}|) = 2\Phi(-3.32) = 2 \times 0.000 = 0.000 \text{ (fino a 4 decimali)}$$

Il valore-p è minore di 0.01, quindi rigettiamo l'ipotesi nulla che non vi è differenza di genere all'1%.

- (c) L'intervallo di confidenza al 95% per la differenza di genere β_1 è $\{2.79 \pm 1.96 \times 0.84\} = (1.1436, 4.4364)$

- (d) Il salario medio delle donne nel campione è $\hat{\beta}_0 = \$12.68/\text{ora}$ Il salario medio degli uomini nel campione è $\hat{\beta}_0 + \hat{\beta}_1 = \$12.68 + \$2.79 = \$15.47/\text{ora}$

- (e) Il modello di regressione con variabile binaria (dummy) può essere scritto sia

$$Wage = \beta_0 + \beta_1 Male + u_i,$$

sia

$$Wage = \gamma_0 + \gamma_1 Female + v_i.$$

Nella prima regressione, *Male* è uguale ad 1 per gli uomini e a 0 per le donne; β_0 è la media della popolazione per le donne e $\beta_0 + \beta_1$ è la media della popolazione per gli uomini. Nella seconda regressione, *Female* è uguale ad 1 per le donne e 0 per gli uomini; γ_0 è la media della popolazione per gli uomini e $\gamma_0 + \gamma_1$ è la media della popolazione per le donne. Quindi troviamo la seguente relazione tra i coefficienti delle due regressioni:

$$\begin{aligned}\gamma_0 &= \beta_0 + \beta_1, \\ \gamma_0 + \gamma_1 &= \beta_0.\end{aligned}$$

Avendo le stime dei coefficienti $\hat{\beta}_0$ e $\hat{\beta}_1$, otteniamo

$$\begin{aligned}\hat{\gamma}_0 &= \hat{\beta}_0 + \hat{\beta}_1 = 15.47 \\ \hat{\gamma}_1 &= \hat{\beta}_0 - \hat{\gamma}_0 = -2.79\end{aligned}$$

Sulla base della relazione tra i coefficienti stimati, per ogni osservazione individuale, i residui OLS sono gli stessi nelle due regressioni: $\hat{u}_i = \hat{v}_i$. Quindi la somma dei quadrati dei residui,

$SSR = \sum_{i=1}^n \hat{u}_i^2$, è la stessa nelle due regressioni. Questo implica che sia $SER = \left(\frac{SSR}{n-1}\right)^{\frac{1}{2}}$ che $R^2 = 1 - \frac{SSR}{TSS}$ non mutano.

In conclusione, facendo la regressione di *Wages* su *Female*, otteniamo

$$\hat{Wage} = 15.47 - 2.79 Female, R^2 = 0.06, SER = 3.10$$