

MODEL REGRESJI LINIOWEJ

1. Dla 10 losowo wybranych studentów zanotowano dane o czasie nauki (X-w godz.) w okresie sesji i otrzymanych ocenach z egzaminu z filozofii (Y).
 - a) Na podstawie poniższych danych oszacować liniową funkcję regresji osiągniętych przez studentów ocen od czasu nauki i zinterpretować,
 - b) Oszacować średnie błędy szacunki,
 - c) Zbadać istotność współczynnika regresji ($\gamma=0,05$)
 - d) Ocenic dopasowanie modelu regresji liniowej do danych empirycznych,
 - e) Jakiej oceny powinien oczekiwać student uczący się 23 godziny (predykcja punktowa i przedziałowa dla $\gamma=0,05$)

i	x_i	y_i	$y_i \cdot x_i$	x_i^2	\hat{y}_i	$e_i = y_i - \hat{y}_i$	e_i^2	$\sum_{i=1}^n (y_i - \bar{y})^2$	$\sum_{i=1}^n (\hat{y}_i - \bar{y})^2$
1	3	2	6	9	2,270	-0,270	0,073	1,690	1,060
2	5	3	15	25	2,489	0,511	0,261	0,090	0,658
3	15	3,5	52,5	225	3,585	-0,085	0,007	0,040	0,080
4	10	3	30	100	3,037	-0,037	0,001	0,090	0,069
5	25	4,5	112,5	625	4,681	-0,181	0,033	1,440	1,907
6	17	3	51	289	3,804	-0,804	0,646	0,090	0,254
7	13	4	52	169	3,366	0,634	0,402	0,490	0,004
8	7	2	14	49	2,708	-0,708	0,501	1,690	0,350
9	23	5	115	529	4,462	0,538	0,289	2,890	1,350
10	6	3	18	36	2,598	0,402	0,162	0,090	0,493
Σ	124	33	466	2056	33,000	0,000	2,375	8,600	6,225

$$\bar{x} = 12,4; \bar{y} = 3,3$$

a) Współczynnik regresji

$$\hat{\alpha} = \frac{n \cdot \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \cdot \sum_{i=1}^n y_i}{n \cdot \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} = \frac{c_{xy}}{s_x^2} = r_{xy} \cdot \frac{s_y}{s_x} = \frac{10 \cdot 466 - 124 \cdot 33}{10 \cdot 2056 - (124)^2} = 0,1096$$

Wydłużenie czasu nauki o godzinę podnosi **średnią ocenę o 0,1096**

Wyraz wolny

$$\hat{\beta} = \frac{\sum_{i=1}^n y_i - \hat{\alpha} \cdot \sum_{i=1}^n x_i}{n} = \bar{y} - \hat{\alpha} \cdot \bar{x} = 3,3 - 0,1096 \cdot 12,4 = 1,9410$$

Przy zerowym czasie nauki **średnia (teoretyczna) ocena** wynosi 1,94 \approx 2

Funkcja regresji liniowej z oszacowanymi parametrami strukturalnymi

$$\hat{y}_i = 0,1096 \cdot x_i + 1,9410$$

$$b) \quad s_e = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n-2}} = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n-2}} = \sqrt{\frac{2,375}{10-2}} = 0,5449$$

Wszystkie czynniki nie uwzględnione w modelu zmieniają **średnio** ocenę o 0,5449

$$s_{\hat{\alpha}} = \sqrt{\frac{s_e^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} = \sqrt{\frac{s_e^2}{\sum_{i=1}^n x_i^2 - n \cdot \bar{x}^2}} = \sqrt{\frac{s_e^2}{(n-1) \cdot s_x^2}} = \sqrt{\frac{0,2969}{2056 - 10 \cdot (12,4)^2}} = 0,0239$$

Przy szacowaniu wartości współczynnika regresji średnia wartość popełnianego błędu wynosi 0,0239.

$$s_{\hat{\beta}} = \sqrt{\frac{S_e^2 \cdot \sum_{i=1}^n x_i^2}{n \sum_{i=1}^n (x_i - \bar{x})^2}} = \sqrt{\frac{S_e^2 \cdot \sum_{i=1}^n x_i^2}{n \cdot (\sum_{i=1}^n x_i^2 - n \cdot \bar{x}^2)}} = s_{\hat{\alpha}} \sqrt{\frac{\sum_{i=1}^n x_i^2}{n}} = 0,0239 \cdot \sqrt{\frac{2056}{10}} = 0,3427$$

Przy szacowaniu wartości wyrazu wolnego średnia wartość popełnianego błędu wynosi 0,3427.

Model regresji liniowej z oszacowanymi parametrami strukturalnymi i stochastycznymi

$$y_i = 0,1096 \cdot x_i + 1,9410 + e_i$$

[0,0239] [0,3427] [0,5449]

Zbadać istotność współczynnika regresji ($\gamma=0,05$)

c) $H_0: \alpha = 0$, nie istnieje regresja liniowa ocen względem czasu nauki w populacji generalnej, współczynnik regresji jest statystycznie nieistotny

$H_1: \alpha \neq 0$, występuje regresja liniowa ocen względem czasu nauki w populacji generalnej, współczynnik regresji jest statystycznie istotny

$$t = \frac{\hat{\alpha}}{s_{\hat{\alpha}}} = \frac{0,1096}{0,0239} = 4,586$$

$$\gamma=0,05 ; v=n-2=10-2=8$$

$$\lambda = \{ t : t \in (-\infty; -t_{\gamma,v}) \cup \langle t_{\gamma,v}; +\infty \rangle \}$$

$$\lambda = \{ t : t \in (-\infty; -2,306) \cup \langle 2,306; +\infty \rangle \}$$

$$t \in \lambda$$

Ponieważ obliczona wartość testu znalazła się w obszarze odrzuceń to istnieją statystyczne podstawy do odrzucenia hipotezy H_0 i przyjęcia hipotezy H_1 . Uznajemy, że istnieje regresja liniowa ocen względem czasu nauki. Decyzję podjęto w przy poziomie istotności $\gamma=0,05$

Oceń dopasowanie modelu regresji liniowej do danych empirycznych,

$$d) \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad 8,600=6,225+2,375$$

Współczynnik determinacji

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{c_{xy}}{s_x^2 \cdot s_y^2} = \frac{c_{xy} \cdot \hat{\alpha}}{s_y^2} = \frac{6,225}{8,600} = 0,724$$

$$R^2 \approx 1 - \frac{s_e^2}{s_y^2}$$

$$R^2 = r_{xy}^2$$

Zmienność czasu nauki wyjaśnia zmienność ocen w 72,4%.

Współczynnik indeterminacji $\phi^2 = 1 - R^2$

$$R^2 + \phi^2 = 1$$

$$\phi^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{c_{xy}^2}{s_x^2 \cdot s_y^2} = 1 - \frac{c_{xy} \cdot \hat{\alpha}}{s_y^2} = \frac{2,375}{8,600} = 0,276$$

$$\phi^2 \approx \frac{s_e^2}{s_y^2}$$

Zmienność czasu nauki nie wyjaśnia zmienności ocen w 27,6%.

Jakiej oceny powinien oczekiwać student uczący się 23 godziny (predykcja punktowa i przedziałowa dla $\gamma=0,05$)

e) $x_p=23$; $\hat{y}_p = \hat{\alpha} \cdot x_p + \hat{\beta}$

Predykcja punktowa:

$$\hat{y}_p = 0,1096 \cdot 23 + 1,9410 = 4,4618 \approx 4,5$$

Prognozowana ocena dla studenta uczącego się 23 godziny wynosi 4,5.

$$s_{(\hat{y}_p)} = s_e \sqrt{1 + \frac{1}{n} + \frac{(x_p - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} = 0,5449 \sqrt{1 + \frac{1}{10} + \frac{(23-12,4)^2}{518,4}} = 0,6253$$

Prognozując ocenę dla studenta uczącego się 23 godziny standardowy błąd prognozy wynosi 0,6253.

Predykcja przedziałowa:

$$P(\hat{y}_p - t_{\gamma, n-2} \cdot s_{(\hat{y}_p)} < y_p < \hat{y}_p + t_{\gamma, n-2} \cdot s_{(\hat{y}_p)}) = 1 - \gamma$$

$$4,4618 - 2,306 \cdot 0,6253 < y_p < 4,4618 + 2,306 \cdot 0,6253 \quad \Rightarrow \quad 3,0 < y_p < 5,9$$

Przedział o końcówka $(3,0 ; 5,9)$ jest jednym z przedziałów, które z prawdopodobieństwem $0,95$ obejmują prognozowaną ocenę studenta uczącego się 23 godziny.