

Statistika: Dvodimenzionalne varijable

Motivacija – Primjer 9.1 (6.2)

Gustoća (kg/m^3)	Tlačna čvrstoća (MPa)
2236	25.2
2244	25.2
2244	25.2
2244	25.3
2244	25.7
2253	25.4
2253	25.8
2262	25.4
2272	27.5
2280	27.5
2290	27.1


Primjer 9.1 (Primjer 6.2)

2290	28.1
2290	28.8
2295	27.1
2295	29.7
2307	29.9
2315	29.5
2325	29.3
2334	28.7
Gustoća (kg/m ³)	Tlačna čvrstoća (MPa)


Tablica: Podatci o gustoći i tlačnoj čvrstoći betona ¹

¹A. Mattacchione i L. Mattacchione, "Correlation Between 28-Day Strength and Density", Concrete International, 1995 (3), str. 37-41


Dijagram raspršenja (podataka) tlačne čvrstoće i gustoće



Metoda najmanjih kvadrata



Pravac najboljeg pristajanja



Pearsonov koeficijent korelacije

- jedan od načina mjerenja zavisnosti dviju varijabli
- za opažene vrijednosti $(x_1, y_1), \dots, (x_n, y_n)$ od (X, Y) definiramo ga kao

$$r_{XY} = \frac{S_{XY}}{\sqrt{S_{XX}}\sqrt{S_{YY}}},$$

gdje su

$$S_{XX} = \sum_{i=1}^n (x_i - \bar{x}_n)^2, \quad S_{YY} = \sum_{i=1}^n (y_i - \bar{y}_n)^2, \quad S_{XY} = \sum_{i=1}^n (x_i - \bar{x}_n)(y_i - \bar{y}_n).$$


- vrijedi

$$-1 \leq r_{XY} \leq 1$$


Pearsonov koeficijent korelacije

- (i) $|r_{XY}| = 1$ ako i samo ako opažanja $(x_1, y_1), \dots, (x_n, y_n)$ leže na istom pravcu (i $S_{XX} > 0, S_{YY} > 0$)
- (ii) manji $|r_{XY}|$ znači “manji stupanj linearne zavisnosti” od opažanja $x_1, \dots, x_n$ i $y_1, \dots, y_n$
- (iii) $r_{XY} = 0$ znači da su $x - \bar{x}_n$ i $y - \bar{y}_n$ “ortogonalni”


Ilustracija podataka s različitim koeficijentima korelacije




Ilustracija podataka s različitim koeficijentima korelacije




Ilustracija podataka s različitim koeficijentima korelacije



Ilustracija podataka s različitim koeficijentima korelacije



Koeficijent korelacije tlačne čvrstoće i gustoće



- pretpostavlja povezanost između zavisne varijable Y i jedne nezavisne varijable X
- pretpostavljamo linearni model (linearnu povezanost)


$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, n,$$

gdje varijable $\varepsilon_1, \dots, \varepsilon_n$ predstavljaju pogreške (nezavisne i jednako distribuirane s raspodjelom $N(0, \sigma^2)$)

Jednostavna linearna regresija

- koeficijenti β_0 i β_1 su nepoznati **regresijski parametri** koje u postupku modeliranja procijenimo na osnovi opažanja
- $y_1, \dots, y_n$ su stvarne izmjerene vrijednosti
- $y'_i = \beta_0 + \beta_1 x_i$ vrijednosti koje bismo očekivali za određeni x_i na temelju postavljenog modela
- da bismo dobili pravac koji bi najbolje pristajao svim podacima mora se minimizirati udaljenost između y_i i y'_i .

Metoda najmanjih kvadrata



- procjena $\hat{\beta}_0, \hat{\beta}_1$ parametara β_0, β_1 :


$$\hat{\beta}_0 = \bar{y}_n - \bar{x}_n \hat{\beta}_1, \quad \hat{\beta}_1 = \frac{S_{XY}}{S_{XX}}$$

- u svrhu određivanja reprezentativnosti modela najčešće koristimo **koeficijent determinacije**:

$$r_{XY}^2 = \frac{S_{XY}^2}{S_{XX} S_{YY}}, \quad 0 \leq r_{XY}^2 \leq 1$$

- što je r_{XY}^2 bliži 1, to je model reprezentativniji

Pravac najboljeg pristajanja (tlačna čvrstoća i gustoća)



Anscombeov kvartet - I

x	y
10	8.04
8	6.95
13	7.58
9	8.81
11	8.33
14	9.96
6	7.24
4	4.26
12	10.84
7	4.82
5	5.68

$$\bar{x}_{11} = 9, s_x^2 = 11, \bar{y}_{11} = 7.5, s_y^2 = 4.127, r_{XY} = 0.8164, y = 3 + 0.5x$$

Anscombeov kvartet - II

x	y
10	9.14
8	8.14
13	8.74
9	8.77
11	9.26
14	8.10
6	6.13
4	3.1
12	9.13
7	7.26
5	4.74

$$\bar{x}_{11} = 9, s_x^2 = 11, \bar{y}_{11} = 7.5, s_y^2 = 4.128, r_{XY} = 0.8162, y = 3 + 0.5x$$

Anscombeov kvartet - III

x	y
10	7.46
8	6.77
13	12.74
9	7.11
11	7.81
14	8.84
6	6.08
4	5.39
12	8.15
7	6.42
5	5.73


$$\bar{x}_{11} = 9, s_x^2 = 11, \bar{y}_{11} = 7.5, s_y^2 = 4.123, r_{XY} = 0.8163, y = 3 + 0.5x$$

Anscombeov kvartet - IV


x	y
8	6.58
8	5.76
8	7.71
8	8.84
8	8.47
8	7.04
8	5.26
19	12.5
8	5.56
8	7.91
8	6.89

$$\bar{x}_{11} = 9, s_x^2 = 11, \bar{y}_{11} = 7.5, s_y^2 = 4.123, r_{XY} = 0.8165, y = 3 + 0.5x$$


Anscombeov kvartet - I



Anscombeov kvartet - II



Anscombeov kvartet - III



Anscombeov kvartet - IV

