

Wskaźówki i odpowiedzi do zadań domowych z SMWD Laboratorium 4: Zadanie 2, Zadanie 6, Zadanie 8, Zadanie 10

Zadanie 2

1) Model regresji: $Y = \beta_0 + \beta_1 X + \epsilon$, gdzie Y – cholesterol, X - wiek.

2) Wprowadzić dane: lab4.zad2 (*cholesterol, wiek*).

3) Wykres rozproszenia i współczynnik korelacji:

Analizuj >> Korelacje

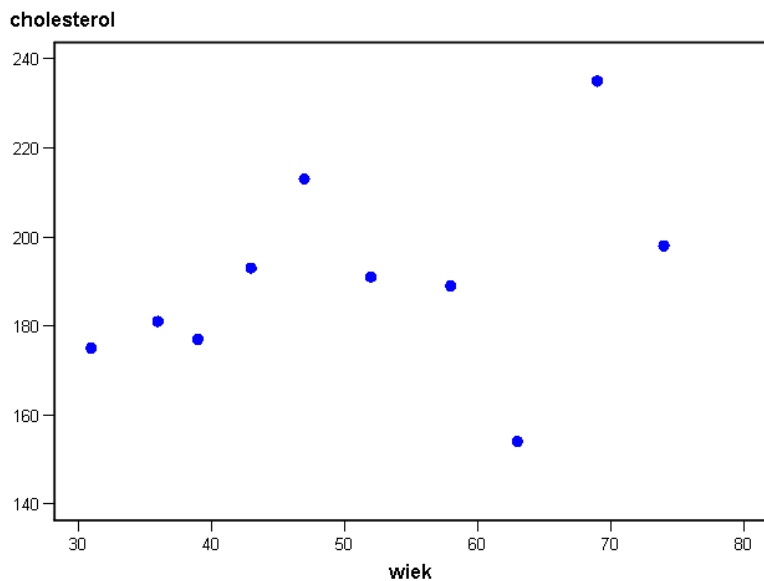
Role zadania: *cholesterol* >> zmienne analizowane, *wiek* >> koreluj z

Opcje: korelacja Pearsona

Rezultaty: utwórz wykresy punktowe

URUCHOM

Współczynniki korelacji Pearsona, N = 10 Prob > r przy H0: R0=0	
	cholesterol
wiek	0.35672
	0.3116



Zadanie 6

1) Model regresji: $\sqrt{Y} = \beta_0 + \beta_1 X + \epsilon$, gdzie Y – wypadki, X - auta.

2) Wprowadzić dwa zbiory danych: lab4.zad6 (*auta, wypadki*), lab4.zad6p (*auta*)

3) Wykres rozproszenia i współczynnik korelacji ($\sqrt{\text{wypadki}}$ >> zmienne analizowane, *auta* >> koreluj z)
 $\rho = 0.84888$, p-value = 0.0002.

4) Analizuj >> Regresja >> Liniowa

Role zadania: $\sqrt{\text{wypadki}}$ >> zmienna zależna, *auta* >> zmienne objaśniające

Dalej jak w zadaniach 3, 4

URUCHOM

5) Postawić odpowiednią hipotezę. Wynik dla testu F:

$F = 28.37$, p-value = 0.0002 \Rightarrow istnieje związek między zmienną \sqrt{Y} a X

6) $\sqrt{y} = 2.32509 + 0.00091517x$

7) $R^2 = 0.7206$

8) Prognoza $\sqrt{Y}^{\wedge} = 5.528 \Rightarrow Y^{\wedge} = (5.528)^2$

9) Sprawdzenie założeń: dla testu Shapiro-Wilka p-value = 0.6339

Zadanie 8

- 1) Model regresji: $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon$, gdzie Y – wartość budynku, X_1 – powierzchnia, X_2 – odległość.
- 2) Tworzymy dwa zbiory: lab4.zad8 (wartość, powierzchnia, odległość), lab4.zad8p (powierzchnia, odległość)
- 3) Analizuj >> Regresja >> Liniowa
Role zadania: wartość >> zmienna zależna, powierzchnia, odległość >> zmienne objaśniające
Dalej jak w Materiałach pomocniczych dla regresji wielorakiej (lub zadaniu 7)

URUCHOM

- 4) Postawić odpowiednią hipotezę. Wynik dla testu F:
 $F = 26.67$, $p\text{-value} < 0.0010 \Rightarrow$ istnieje związek między zmienną Y a którąkolwiek z X_1, X_2
- 5) Wyniki testów istotności t:
dla X_1 (powierzchnia) $t = 6.15$, $p\text{-value} = 0.0008$
dla X_2 (odległość) $t = 2.71$, $p\text{-value} = 0.0352$
- 6) $y = -19.87 + 1.93x_1 + 19.4x_2$
- 7) $R^2 = 0.8989$
- 8) prognoza $Y^{\wedge} = 346.988$

Zadanie 10

- 1) Przyjmujemy następujący model regresji: $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_5 + \epsilon$,
gdzie: Y (mpg) – zużycie paliwa,
 X_1 (accel) – przyspieszenie,
 X_2 (horsepower) – moc silnika,
 X_3 (cylinders) – liczba cylindrów,
 X_4 (weight) – waga samochodu,
 X_5 (year) – rok produkcji.

- 2) Wynik dla testu F:
 $F = 88.88$, $p\text{-value} < 0.0001$
- 3) Miara dopasowania $R^2 = 0.7553$
- 4) Wyniki testów istotności t:
dla X_1 (accel) $p\text{-value} = 0.0998$
dla X_2 (horsepower) $p\text{-value} = 0.0468$
dla X_3 (cylinders) $p\text{-value} = 0.0180$
dla X_4 (weight) $p\text{-value} < 0.0001$
dla X_5 (year) $p\text{-value} = 0.0004$
- 5) Usuwanie z modelu nieistotnej zmiennej X_1 (accel):

$$Y = \beta_0 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \beta_5 X_5 + \epsilon,$$
$$F = 109.1, p\text{-value} < 0.0001$$
$$y = -10.09 - 0.11x_2 + 0.95x_3 - 0.01x_4 + 0.80x_5, \quad R^2 = 0.7506$$

Uwaga: Jeśli nie uwzględnimy w modelu regresji wyrazu wolnego, dostaniemy większą wartość $R^2 = 0.9847$