

Kovarianz und Korrelationskoeffizient

$$x := \begin{pmatrix} 21 \\ 28 \\ 35 \\ 46 \\ 55 \end{pmatrix} \quad y := \begin{pmatrix} 1850 \\ 1800 \\ 2230 \\ 2500 \\ 2560 \end{pmatrix} \quad \text{Ausprägungen der Merkmale } x \text{ und } y^1)$$

$n := \text{länge}(x) = 5$ Anzahl der Wertepaare von x und y

$\text{ORIGIN} \equiv 1$ Startwert für alle verwendeten Indizes

$i := \text{ORIGIN} \dots n$ Index der Merkmalsausprägungen


$$x_d := \frac{1}{n} \cdot \sum_{i=1}^n x_i = 37 \quad \text{Durchschnittliche Ausprägung des Merkmals } x$$

$\text{mittelwert}(x) = 37$

$$y_d := \frac{1}{n} \cdot \sum_{i=1}^n y_i = 2188 \quad \text{Durchschnittliche Ausprägung des Merkmals } y$$

$\text{mittelwert}(y) = 2188$

Streudiagramm



1) Quelle für das Beispiel: A. Quatember, Statistik ohne Angst vor Formeln, 2. Aufl. München 2008, S. 67 ff.

Kovarianz und Korrelationskoeffizient

$\Delta x := \min(x) \dots \max(x)$ Parameter für die folgenden Grafiken

$\Delta y := \min(y) \dots \max(y)$

$$B1 := \begin{cases} x_1 \dots x_d & \text{if } x_1 < x_d \\ x_d \dots x_1 & \text{otherwise} \end{cases} \quad H1 := \begin{cases} y_1 \dots y_d & \text{if } y_1 < y_d \\ y_d \dots y_1 & \text{otherwise} \end{cases}$$

Abweichung 1:
 $(x_1 - x_d) \cdot (y_1 - y_d) = 5408$

$$B2 := \begin{cases} x_2 \dots x_d & \text{if } x_2 < x_d \\ x_d \dots x_2 & \text{otherwise} \end{cases} \quad H2 := \begin{cases} y_2 \dots y_d & \text{if } y_2 < y_d \\ y_d \dots y_2 & \text{otherwise} \end{cases}$$

Abweichung 2:
 $(x_2 - x_d) \cdot (y_2 - y_d) = 3492$

$$B3 := \begin{cases} x_3 \dots x_d & \text{if } x_3 < x_d \\ x_d \dots x_3 & \text{otherwise} \end{cases} \quad H3 := \begin{cases} y_3 \dots y_d & \text{if } y_3 < y_d \\ y_d \dots y_3 & \text{otherwise} \end{cases}$$

Abweichung 3:
 $(x_3 - x_d) \cdot (y_3 - y_d) = -84$


$$B4 := \begin{cases} x_4 \dots x_d & \text{if } x_4 < x_d \\ x_d \dots x_4 & \text{otherwise} \end{cases} \quad H4 := \begin{cases} y_4 \dots y_d & \text{if } y_4 < y_d \\ y_d \dots y_4 & \text{otherwise} \end{cases}$$

Abweichung 4:
 $(x_4 - x_d) \cdot (y_4 - y_d) = 2808$



$$B5 := \begin{cases} x_5 \dots x_d & \text{if } x_5 < x_d \\ x_d \dots x_5 & \text{otherwise} \end{cases} \quad H5 := \begin{cases} y_5 \dots y_d & \text{if } y_5 < y_d \\ y_d \dots y_5 & \text{otherwise} \end{cases}$$

Abweichung 5:
 $(x_5 - x_d) \cdot (y_5 - y_d) = 6696$



Abweichung 1 als Fläche



Kovarianz und Korrelationskoeffizient



Kovarianz und Korrelationskoeffizient



Kovarianz und Korrelationskoeffizient

Wenn x und y die Grundgesamtheit darstellen:

$$\frac{1}{n} \cdot \sum_{i=1}^n [(x_i - x_d) \cdot (y_i - y_d)] = 3664 \quad \text{Empirische Kovarianz}$$

$$\text{kvar}(x, y) = 3664$$

$$\sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (x_i - x_d)^2} = 12.215 \quad \text{Standardabweichung von x}$$

$$\text{stdev}(x) = 12.215$$

$$\sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (y_i - y_d)^2} = 316.948 \quad \text{Standardabweichung von y}$$

$$\text{stdev}(y) = 316.948$$

Wenn x und y eine Stichprobe darstellen:

$$\frac{1}{n-1} \cdot \sum_{i=1}^n [(x_i - x_d) \cdot (y_i - y_d)] = 4580 \quad \text{Kovarianz einer Stichprobe}$$

$$\sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - x_d)^2} = 13.657 \quad \text{Standardabweichung von x}$$

$$\text{Stdev}(x) = 13.657$$

$$\sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n (y_i - y_d)^2} = 354.359 \quad \text{Standardabweichung von y}$$

$$\text{Stdev}(y) = 354.359$$

Unabhängig davon, ob x und y die Grundgesamtheit oder eine Stichprobe darstellen:

$$\frac{\sum_{i=1}^n [(x_i - x_d) \cdot (y_i - y_d)]}{\sqrt{\sum_{i=1}^n (x_i - x_d)^2} \cdot \sqrt{\sum_{i=1}^n (y_i - y_d)^2}} = 0.946 \quad \text{Korrelationskoeffizient}$$

$$\text{korrr}(x, y) = 0.946$$