



Lösungsvorschläge zum 2. Übungsblatt zur „Einführung in die Stochastik“

Lösung zur Aufgabe 6

(3 Punkte)

Datenpunkte der Größe nach aufsteigend geordnet (hier $n = 10 \leftrightarrow$ gerade):

1, 1.3, 2.3, 2.7, 3.3, 3.7, 4, 4, 5, 5

Mittel: $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \rightarrow \bar{x} = 3.23$

Median: $\tilde{x} = \begin{cases} x_{\frac{n+1}{2}}, & \text{falls } n \text{ ungerade,} \\ \frac{1}{2}(x_{(\frac{n}{2})} + x_{(\frac{n+1}{2})}), & \text{falls } n \text{ gerade.} \end{cases} \rightarrow \tilde{x} = 3.5$

(a) Spannweite: $r := x_{max} - x_{min} \rightarrow r = 4$

Varianz: $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \rightarrow s^2 = 1.9468$

Standardabweichung: $s = \sqrt{s^2} \rightarrow s = 1.3953$

Interquartilabstand: $IQR = x_{(\lceil \frac{3}{4}n \rceil)} - x_{(\lceil \frac{1}{4}n \rceil)} \rightarrow IQR = 1.7$

Lösung zur Aufgabe 7

(3 Punkte)

Wir verwenden die Notation aus der Vorlesung.

- (a) Wir müssen die Anzahl der Studenten bestimmen, die zu den Intervallen $I_2 = [-20, 0)$ und $I_3 = [0, 10)$ gehören. D.h. wir suchen n_2 und n_3 . Bezeichnen wir die Balkenhöhen über dem Intervall I_j mit y_j , für $j \in \{1, \dots, 5\}$, so erhalten wir durch Umstellen der Formel aus der Vorlesung:


$$n_2 + n_3 = (y_2 \cdot \lambda(I_2) + y_3 \cdot \lambda(I_3)) \cdot n \approx (0.0165 \cdot 20 + 0.0075 \cdot 10) \cdot 40 = 16.2 \approx 16$$

- (b)

$$\text{Median: } \tilde{x} \approx -0.5$$

$$\text{IQR} \approx 45 - (-30) = 75$$

Lösung zu Aufgabe 6 b)



Lösung zur Aufgabe 8

(3 Punkte)

- (b) Seien x_i die Ausgaben pro Student (in Euro) in Zeile i der Tabelle und y_i die Arbeitslosenquote (in Prozent) in Zeile i der Tabelle. Nach der Formel aus der Vorlesung hat die Regressionsgerade die Form

$$y = \hat{a}(x - \bar{x}) + \bar{y},$$

mit

$$\hat{a} = \frac{s_{xy}}{s_x^2},$$

$$s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}),$$

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2,$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i,$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

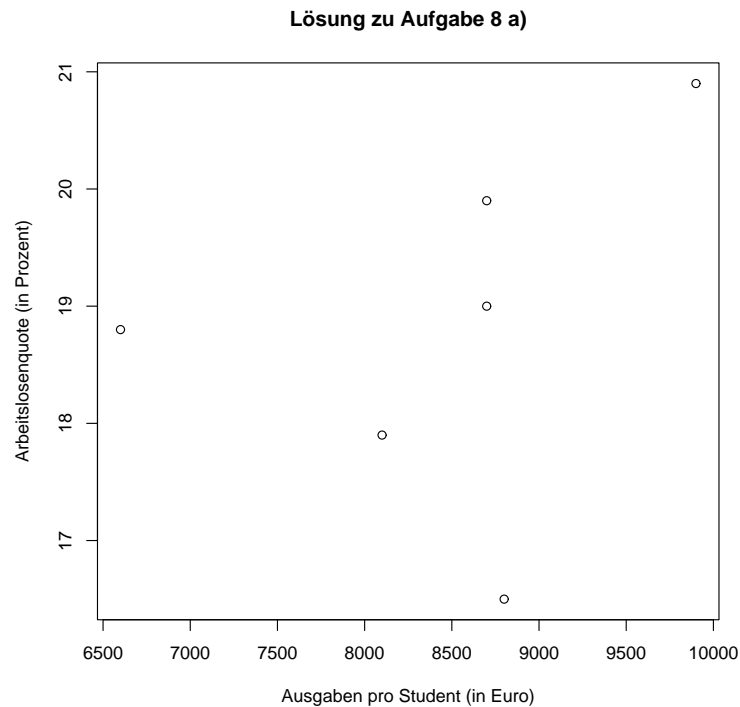


Abbildung 1: Aufgabe 8

und $n = 6$. Einsetzen der Werte ergibt

$$\begin{aligned}\bar{x} &= \frac{1}{6}(8100 + 6600 + 8700 + 8700 + 9900 + 8800) \approx 8466.667 \\ \bar{y} &= \frac{1}{6}(17.9 + 18.8 + 19.6 + 19 + 20.9 + 16.5) \approx 18.7833 \\ s_{xy} &= \frac{1}{5}((8100 - 8466.667) \cdot (17.9 - 18.7833) + \dots + (8800 - 8466.667) \cdot (16.5 - 18.7833)) \\ &\approx 561.33 \\ s_x^2 &= \frac{1}{5}((8100 - 8466.667)^2 + \dots + (8800 - 8466.667)^2) \approx 118667 \\ \hat{a} &\approx 0.000476\end{aligned}$$

und damit

$$y = 0.000476 \cdot (x - 8466.667) + 18.7833.$$

- (c) Lässt man den Sachsen-Anhalt Datenpunkt weg, so wird die Steigung der Regressionsgeraden negativ (was auch zu einer Änderung des y-Achsenabschnitts führt).

$$\begin{aligned}\bar{x} &= 8180 \\ \bar{y} &= 18.42 \\ \hat{a} &= -0.0001977830\end{aligned}$$

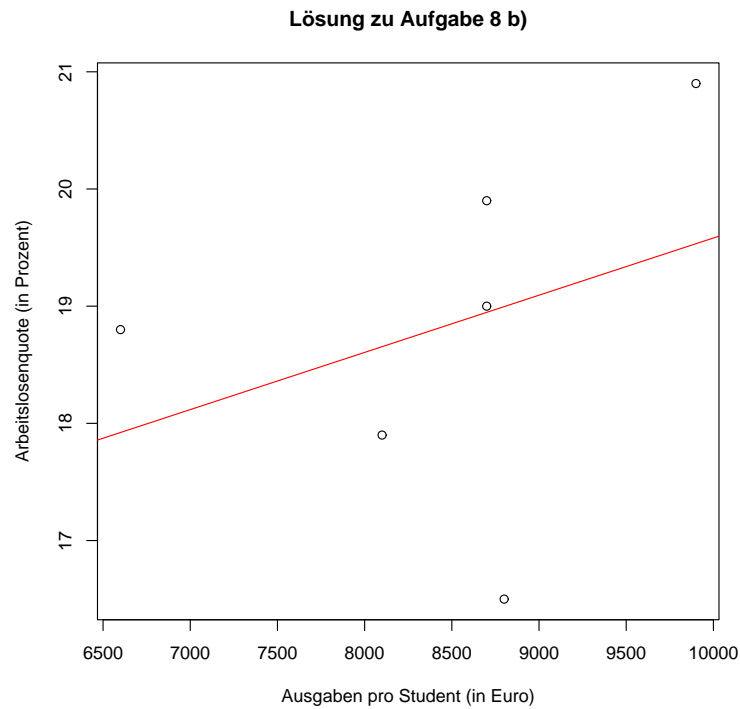


Abbildung 2: Aufgabe 8

Lösung zur Aufgabe 9

(3 Punkte)

(a)

$$\begin{aligned}
 \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 &= \frac{1}{n} \sum_{i=1}^n (x_i^2 - 2x_i\bar{x} + \bar{x}^2) \\
 &= \frac{1}{n} \sum_{i=1}^n x_i^2 - 2\bar{x} \frac{1}{n} \sum_{i=1}^n x_i + \frac{1}{n} \sum_{i=1}^n \bar{x}^2 \\
 &= \frac{1}{n} \sum_{i=1}^n x_i^2 - 2\bar{x}^2 + \bar{x}^2 \\
 &= \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 \\
 \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) &= \frac{1}{n} \sum_{i=1}^n (x_i y_i - \bar{x} y_i - \bar{y} x_i + \bar{x} \bar{y}) \\
 &= \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \frac{1}{n} \sum_{i=1}^n y_i - \bar{y} \frac{1}{n} \sum_{i=1}^n x_i + \frac{1}{n} \sum_{i=1}^n \bar{x} \bar{y} \\
 &= \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \bar{y}
 \end{aligned}$$

(b) Die empirische Korrelation ist definiert als

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}.$$

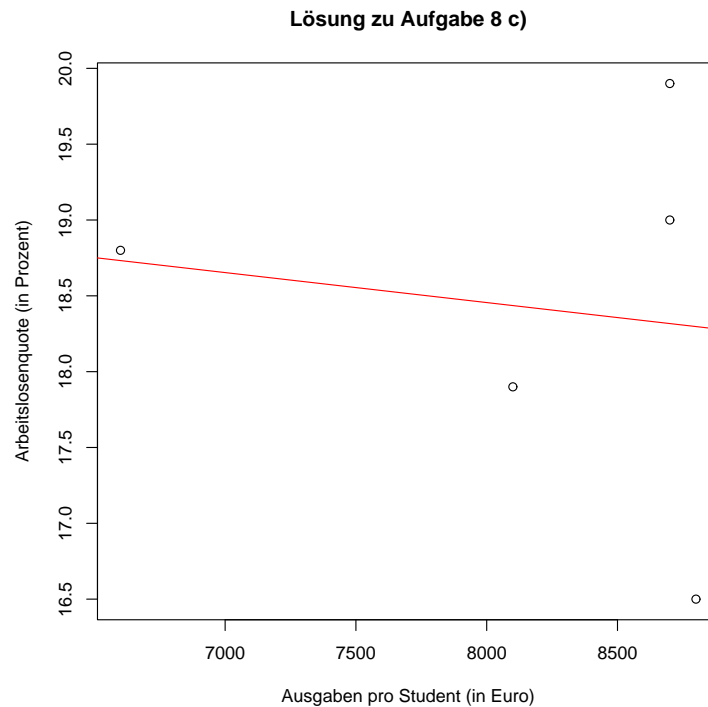


Abbildung 3: Aufgabe 8

Die Werte von s_{xy} und s_x wurden schon in Aufgabe 8 berechnet. Wegen

$$s_y^2 \approx 2.350667$$

folgt dann

$$r_{xy} = \frac{s_{xy}}{\sqrt{s_x^2 \cdot s_y^2}} \approx 0.3456429.$$

- (c) Da das Vorzeichen der empirischen Korrelation mit dem Vorzeichen der Steigung der Regressionsgeraden übereinstimmt, ist im vorliegenden Fall die Steigung der Regressionsgeraden positiv, da $r_{xy} = 0.3456429 > 0$.
- (d) Das Umrechnen der Einheiten kann man als Multiplikation mit einer positiven Konstanten realisieren. Anstelle der Daten $(x_1, y_1), \dots, (x_n, y_n)$ betrachten wir also die Datenpunkte $(z_1, w_1), \dots, (z_n, w_n)$ mit $(z_i, w_i) = (ax_i, by_i)$ für $i = 1, \dots, n$. Dann gilt:

$$\bar{z} = \frac{1}{n} \sum_{i=1}^n z_i = \frac{1}{n} \sum_{i=1}^n ax_i = a \frac{1}{n} \sum_{i=1}^n x_i = a \cdot \bar{x}$$

und genauso

$$\bar{w} = b \cdot \bar{y}.$$

Damit erhalten wir

$$\begin{aligned}
 s_{zw} &= \frac{1}{n-1} \sum_{i=1}^n (z_i - \bar{z}) \cdot (w_i - \bar{w}) \\
 &= \frac{1}{n-1} \sum_{i=1}^n (ax_i - a\bar{x}) \cdot (by_i - b\bar{y}) \\
 &= \frac{1}{n-1} \sum_{i=1}^n a(x_i - \bar{x}) \cdot b(y_i - \bar{y}) \\
 &= abs_{xy}, \\
 s_z^2 &= \frac{1}{n-1} \sum_{i=1}^n (z_i - \bar{z})^2 \\
 &= \frac{1}{n-1} \sum_{i=1}^n (ax_i - a\bar{x})^2 \\
 &= \frac{1}{n-1} \sum_{i=1}^n a^2(x_i - \bar{x})^2 \\
 &= a^2 s_x^2.
 \end{aligned}$$

und

$$\begin{aligned}
 s_w^2 &= \frac{1}{n-1} \sum_{i=1}^n (w_i - \bar{w})^2 \\
 &= \frac{1}{n-1} \sum_{i=1}^n (by_i - b\bar{y})^2 \\
 &= \frac{1}{n-1} \sum_{i=1}^n b^2(y_i - \bar{y})^2 \\
 &= b^2 s_y^2.
 \end{aligned}$$

Das bedeutet für die empirische Korrelation

$$r_{zw} = \frac{s_{zw}}{\sqrt{s_z^2 s_w^2}} = \frac{abs_{xy}}{\sqrt{a^2 s_x^2 b^2 s_y^2}} = r_{xy},$$

d.h. die empirische Korrelation ändert sich durch die Umrechnung nicht.