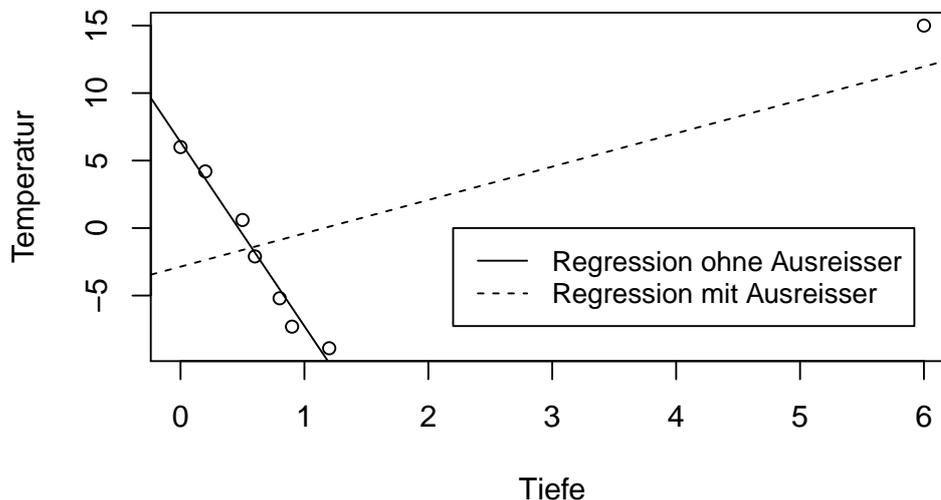


Musterlösung zu Serie 11

1. a) Aus dem Streudiagramm sieht man, dass die ersten 7 Punkte sehr gut durch eine Gerade beschrieben werden. Der letzte Punkt liegt hingegen völlig ausserhalb der Geraden.



Es kann sich um einen groben Fehler handeln; es ist aber auch möglich, dass das lineare Modell zur Beschreibung des Zusammenhangs zwischen Tiefe und Temperatur nicht geeignet ist. (Zum Beispiel könnte der Zusammenhang quadratisch sein, oder stückweise linear. Weitere Möglichkeiten sind denkbar, z.B. Hinweis auf heisse Quelle, etc.)

- b) Sei X die Tiefe und Y die Temperatur. Empirische Korrelation:

$$\rho_{X,Y} = \frac{\sum_{i=1}^7 (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^7 (x_i - \bar{x})^2 \cdot \sum_{i=1}^7 (y_i - \bar{y})^2}} = -0.99$$

wobei \bar{x} und \bar{y} auch ohne den Ausreisser zu berechnen sind.

Ohne Ausreisser sind Tiefe und Temperatur sehr stark negativ korreliert, mit dem Ausreisser aber positiv (0.6)!

- c) In der obigen Figur sind die beiden Regressionsgeraden exakt eingetragen: der Ausreisser bewirkt, dass sich die Gerade fast um 90 dreht, d.h. die kleinste Quadrate Regressionsgerade ist sehr anfällig auf Ausreisser!

Die Schätzungen der Koeffizienten lauten ohne Ausreisser:

$$\begin{aligned} \widehat{\beta}_1 &= \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{(6 + 1.81)(0 - 0.6) + \dots + (-8.9 + 1.81)(1.2 - 0.6)}{(0 - 0.6)^2 + \dots + (1.2 - 0.6)^2} \\ &= -13.64 \end{aligned}$$

und

$$\widehat{\beta}_0 = \bar{y} - \widehat{\beta}_1 \bar{x} = -1.81 - (-13.64) * 0.6 = 6.37.$$

Mit Ausreisser ergibt sich: $\widehat{\beta}_1 = 2.47$ und $\widehat{\beta}_0 = -2.86$.

Diese Schätzungen können auch im **R**-output abgelesen werden.

d) ohne Ausreisser:

Nullhypothese $H_0: \beta_1 = 0$; Alternative $H_A: \beta_1 \neq 0$.

Teststatistik: $T = \frac{\hat{\beta}_1 - 0}{\hat{\sigma}(\hat{\beta}_1)} = \frac{-13.64}{1.01} = -13.5$.

5%-Verwerfungsbereich: $\mathcal{K} = \{T : |T| > t_{7-2, 0.975}\} = \{T : |T| > 2.57\}$

Testergebnis: H_0 wird verworfen; die Steigung kann nicht 0 sein.

Mit Ausreisser ergibt sich $\hat{\beta}_1 = 2.47$ und $\hat{\sigma}(\hat{\beta}_1) = 1.33$. Dies entspricht einem p-Wert von 0.112 und H_0 kann nicht verworfen werden.

Die entsprechenden Outputs erhält man in **R** mit dem Befehl `summary`. Also z.B.

```
> summary(fit1)
```

Call:

```
lm(formula = Temperatur ~ Tiefe)
```

Residuals:

| Min | 1Q | Median | 3Q | Max |
|---------|---------|--------|--------|--------|
| -9.0023 | -4.9011 | 0.7531 | 3.9237 | 8.8616 |

Coefficients:

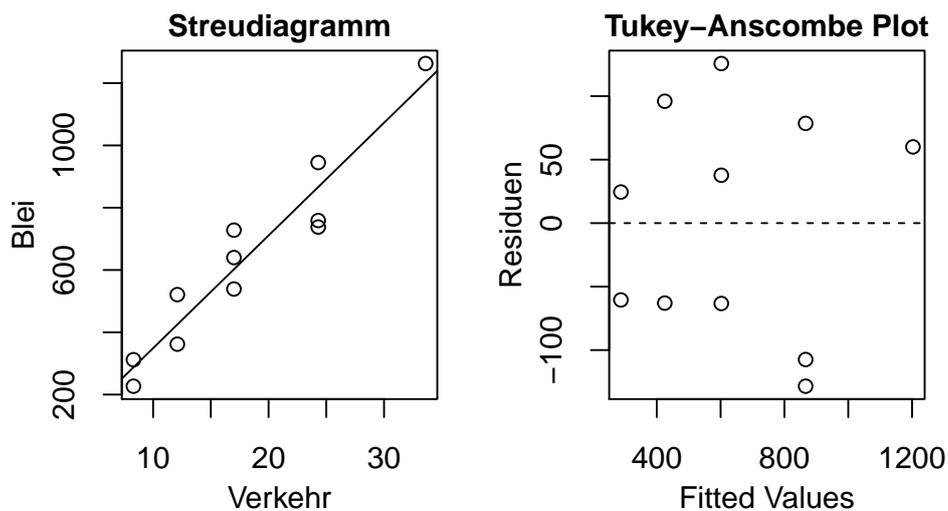
| | Estimate | Std. Error | t value | Pr(> t) |
|-------------|----------|------------|---------|----------|
| (Intercept) | -2.862 | 2.950 | -0.970 | 0.370 |
| Tiefe | 2.470 | 1.327 | 1.861 | 0.112 |

Residual standard error: 6.836 on 6 degrees of freedom

Multiple R-squared: 0.366, Adjusted R-squared: 0.2603

F-statistic: 3.463 on 1 and 6 DF, p-value: 0.1121

2. a)



b) `> summary(strasse.fit)`

Call:

```
lm(formula = blei ~ verkehr, data = strasse)
```

Residuals:

| Min | 1Q | Median | 3Q | Max |
|---------|--------|--------|-------|--------|
| -128.43 | -63.13 | 24.52 | 69.32 | 125.72 |

Coefficients:

| | Estimate | Std. Error | t value | Pr(> t) |
|-------------|----------|------------|---------|--------------|
| (Intercept) | -12.842 | 72.143 | -0.178 | 0.863 |
| verkehr | 36.184 | 3.693 | 9.798 | 4.24e-06 *** |

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 92.19 on 9 degrees of freedom

Multiple R-squared: 0.9143, Adjusted R-squared: 0.9048
 F-statistic: 96.01 on 1 and 9 DF, p-value: 4.239e-06

Wir erhalten die Schätzungen $\hat{\beta}_0 = -12.842$, $\hat{\beta}_1 = 36.184$ und
 $\hat{\sigma}_e = 92.19$ (residual standard error).

$$\implies \text{Blei} = -12.842 + 36.184 \cdot \text{Verkehr}$$

c) **t-Test** für β_1 : Nullhypothese $H_0: \beta_1 = 0$, Alternative $H_A: \beta_1 \neq 0$

Teststatistik: $T = (\hat{\beta}_1 - 0) / \hat{\sigma}(\hat{\beta}_1)$. Unter H_0 gilt: $T \sim t_{n-2}$, also hier $T \sim t_9$

Kritischer Bereich: Tabelle: $t_{9,0.975} = 2.26$ somit $\mathcal{K} = \{|T| > 2.26\}$.

Wert der Statistik: $T = 36.184 / 3.693 = 9.8 > 2.26$ (vgl. Computer-Output).

Die Steigung β_1 ist stark signifikant von Null verschieden (P-Wert = $4.24e - 06$).

d) $x = 40 : y = -12.842 + 36.184 \cdot 40 = 1434.518$

3. 1) a
 2) a
 3) b
 4) d
 5) a
 6) c
 7) c