


Mathematik 3: Übungsblatt - Statistik 2

1. Aufgabe:

Bestimmung von Stoffmengen in Lösungen wie z.B. Wasserproben durch Fotometrie.

Prinzip eines Einstrahl-Fotometers



Stoffe absorbieren eine bestimmte Wellenlänge des Lichtes. Die übrige "Intensität" kann gemessen werden. Als Messgröße dient eine Spannung U [mV], die von der Konzentration eines Stoffes S [mg/l] in der Lösung abhängig ist.


Um eine Zuordnung von Stoffmenge zur Spannung zu erhalten, muss das System kalibriert werden. Dies erfolgt z.B. mit 5 definierten Proben:

Stoffmenge [mg/l]	2	3	6	10	13
Spannung [mV]	6	21	42	83	93

- Erstellen eines Diagramms (x =Stoffmenge, y =Spannung)
- Eine Gerade durch möglichst viele Punkte zeichnen
- Berechnung der Trendlinie (Regressionsgerade $f(x)$)
- Einzeichnen der Regressionsgeraden in das Diagramm
- Vergleich der geschätzten Linie zur berechneten Linie
- Begriffsbestimmung, Berechnung und Interpretation des "Bestimmtheitsmaßes"
- Ermittlung eines Probenwertes: Welche Stoffmenge befindet sich in der Probe bei einer Spannung von 35 mV
 - Ablezen aus dem Diagramm
 - Berechnung nach $f(x)$
- Welchen Schnittpunkt hat die Gerade mit der x -Achse und was bedeutet dieser Schnittpunkt?
- PC-Übung: Ermittlung der Regressionsgeraden mittels Tabellenkalkulation oder Statistik Programm R und Vergleich der Ergebnisse

Lösung:

a)



b), c)

Formeln:

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

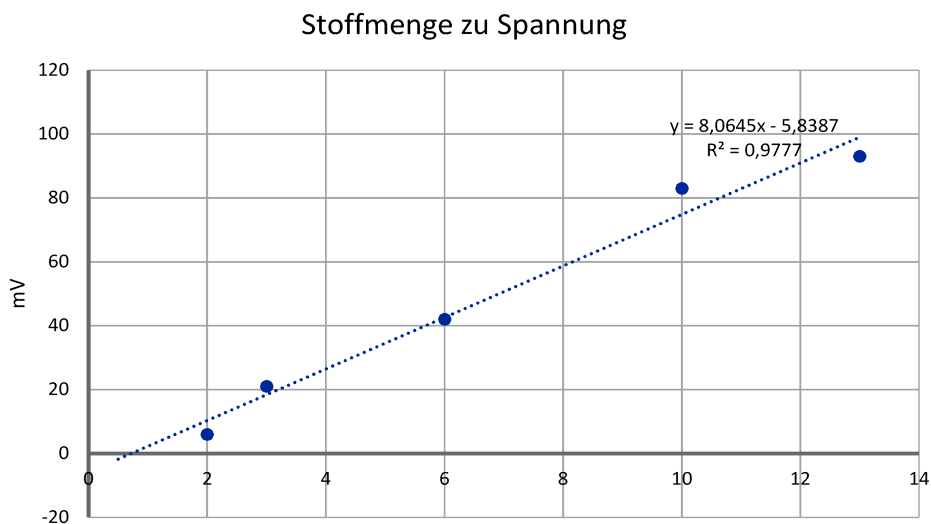
$$S_x^2 = \underbrace{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)}_{\text{Varianz der } x\text{-Werte}},$$

$$\hat{y}_i = \hat{a} + \hat{b}x_i \quad \hat{b} = \frac{S_{XY}}{S_x^2}, \quad \hat{a} = \bar{y} - \hat{b}\bar{x},$$

$$S_{XY} = \underbrace{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \right)}_{\text{Kovarianz}}.$$

		$X_i - \bar{x}$	-4,8	-3,8	-0,8	3,2	6,2
$\bar{x} =$	6,8	$(X_i - \bar{x})^2$	23,04	14,44	0,64	10,24	38,44
$\bar{y} =$	49	S_x^2	86,8				
		$Y_i - \bar{y}$	-43	-28	-7	34	44
		$(X_i - \bar{x}) * (Y_i - \bar{y})$	206,4	106,4	5,6	108,8	272,8
		S_{xy}	700				
$b = S_{xy}/S_x^2$	8,064						
$a = \bar{y} - b * \bar{x}$	-5,838						

d)



- e) Wenn die Punkte gut liegen, kann auch eine geschätzte Linie eine gute Annäherung sein.

Variieren die Punkte zu viel, entsteht hier ein zu großer Freiraum für die Wahl der Geraden.

- f) Das Bestimmtheitsmaß R^2 sagt aus, wie gut eine lineare Regression zu den Daten passt.

$$R^2 = \frac{S_{\hat{y}}^2}{S_y^2}, \quad S_{\hat{y}}^2 = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad \text{bzw.} \quad S_y^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2$$

R^2	Summe $(Y_i - \bar{y})^2$	5774,00				
0,9776864	$y_i = a + b x_i$	10,29	18,35	42,55	74,81	99,00
	$(y_i - \bar{y})^2$	1498,44	939,13	41,62	665,97	2500,00
	Summe $(y_i - \bar{y})^2$	5645,16				

Je näher an 1, desto besser!

- g) Gemäß Ablesen an der Geraden: Eine Spannung von 35 mV entspricht 5 mg/l des Stoffes.

Berechnung: $x = (y - a)/b$ D.h. $x = (35 \text{ mV} - (-5,8 \text{ mV}))/8,06 \text{ mV} \cdot 1/\text{mg} = 5,06 \text{ mg/l}$

- h) Schnittpunkt bei etwa 0,5 mg/l \Rightarrow Nachweisgrenze.

Ab 0,5 mg/l kann erst eine Spannung gemessen werden.

Berechnung: $Y = 0 \Rightarrow 0 = a + bx \Rightarrow x = (0 - a)/b = 5,8 \text{ mV}/8,06 \text{ mV} \cdot 1/\text{mg} = 0,7 \text{ mg/l}$

2. Aufgabe:

Führen Sie eine lineare Regressionsanalyse an dem aus dem Skript bekannten Sektor-Beispiel (Preis-Nachfrage-Problem) mit **R** durch.

Laden/Shop	i	1	2	3	4	5	6
Preis einer Flasche	x_i	20	16	15	16	13	10
verkaufte Menge	y_i	0	3	7	4	6	10

- Definieren Sie zunächst zwei Variablen/Vektoren **X** und **Y** in R entsprechend der Stichprobentabelle.
- Erstellen Sie einen Übersichtsplot (Streudiagramm) von **X** und **Y** in R.
- Erstellen Sie eine KQ (Kleinste Quadrate)-Schätzung. Verwenden Sie dazu den Befehl `lm` ('linear Modell'). Machen Sie sich mit dem `lm` Befehl vertraut (s. z.B. help-Menü) und schreiben Sie das Modell in das Objekt `Modell` ('`~`' befindet sich auf der Taste '`*`', '+' zusammen mit '`ALT`').
- Ermitteln Sie den Korrelationskoeffizienten b , Schnittpunkt (Intercept) a und somit die Gleichung der Regressionsgerade ($\hat{y} = a + bx$).
- Wenden Sie den Befehl 'summary' auf das Modell an und interpretieren Sie die Ausgaben insbesondere: Multiple R-squared.
- Zeichnen Sie die Regressionsgerade in das Streudiagramm mit ein.
- Verwenden Sie die Funktion `predict` um eine Vorhersage für einen beliebigen Wert x , also den Preis auf die zu erwartende verkaufte Menge y zu erhalten. Schreiben Sie dazu die Funktion `predict` in das Objekt `Vorhersage` mit einem Konfidenzbereich von 95%.

h) (Zusatzaufgabe) Geben Sie das Vorrassung-Modell mit ihrem Vertrauensbereich als Grafik aus mit dem Befehl `matplot`.

Lösung:

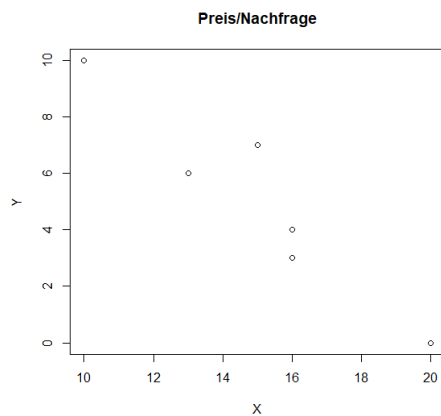
a) • Mit Eingabeaufforderung: `> X <- scan()` bzw. `> Y <- scan()`

• Direkt:

```
> X <- c(20, 16, 15, 16, 13, 10)
```

```
> Y <- c(0, 3, 7, 4, 6, 10)
```

b) `> plot(X,Y, main="Preis/Nachfrage")`



c) `> Modell <- lm(Y ~ X)`

```
> Modell
```

Call:

```
lm(formula = Y ~ X)
```

Coefficients:

```
(Intercept)      X
```

```
19.7321      -0.9821
```

d) $\hat{y} = 19.7321 - 0.9821 \cdot x$

```
> summary(Modell)
```

```
Call:
```

```
lm(formula = Y ~ X)
```

```
Residuals:
```

```
      1      2      3      4      5      6  
-0.08929 -1.01786  2.00000 -0.01786 -0.96429  0.08929
```

```
Coefficients:
```

```
              Estimate Std. Error t value Pr(>|t|)  
(Intercept)  19.7321     2.5016   7.888  0.00140 **  
X            -0.9821     0.1634  -6.010  0.00386 **
```

```
---
```

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

```
Residual standard error: 1.223 on 4 degrees of freedom
```

```
Multiple R-squared:  0.9003,    Adjusted R-squared:  0.8754
```

```
F-statistic: 36.12 on 1 and 4 DF,  p-value: 0.003859
```

e) > |

Interpretation der Werte:

Residuals:

Abweichung zwischen den Y -Werten zur Modellschätzung und den über das Modell geschätzten Y -Werten.

Coefficients:

Angaben zur Signifikanz der geschätzten Parameter.

Zusätzlich:

Korrelationskoeffizient (r) (auch: `> r <- cor(X,Y)`)

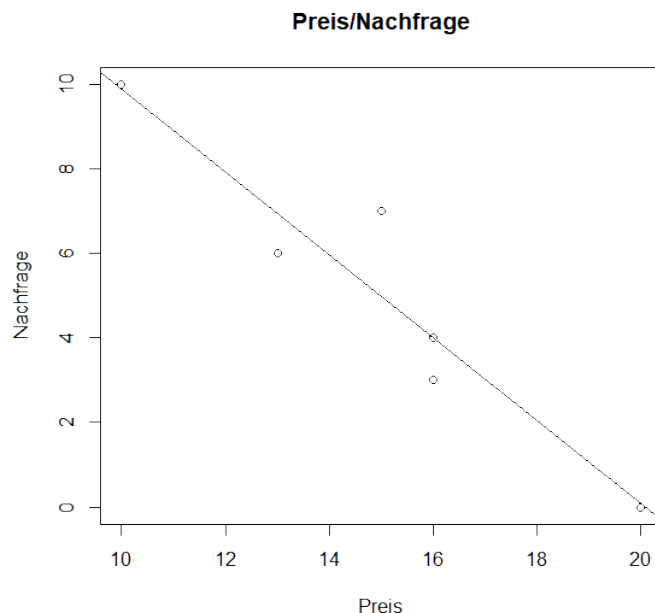
Maß dafür, ob negative oder positive Korrelation vorliegt (-1.. 0 ..1).

Multiple R-squared, Bestimmtheitsmaß r^2 : `> r^2`

der eigentliche lineare Übereinstimmungsfaktor (0..1).

f) `> plot(X,Y, main="Preis/Nachfrage", xlab="Preis", ylab="Nachfrage")`

```
> abline(Modell)
```



```
f) > neu <- data.frame(X=sort(X))
> X
[1] 20 16 15 16 13 10
> neu
  X
1 10
2 13
3 15
4 16
5 16
6 20
> vorhersage <- predict(Modell, neu, interval = "c", level = 0.95)
> vorhersage
      fit      lwr      upr
1 9.91071429  7.252124 12.569305
2 6.96428571  5.307513  8.621058
3 5.00000000  3.613845  6.386155
4 4.01785714  2.559333  5.476382
5 4.01785714  2.559333  5.476382
6 0.08928571 -2.569305  2.747876
```

```
g) > matplot(neu, Vorhersage, lty=c(1,2,2), type = "l", main = "Preis/Nachfrage",
+ xlab="Preis in Euro")
```

