

Mathematik für Natur- und Sozialwissenschaftler

- Blatt 10 -

Abgabe: Mittwoch, den 27.06.2012, 12:10 Uhr vor der Vorlesung

Skript und Aufgabenblätter: Im Internet unter www.mathematik.uni-marburg.de/~lohoefer/

Lektürehinweis: Skript Kap 3.1

Wichtige Begriffe: Lineare Regression, Korrelationskoeffizient r (von Pearson).

1. Bei der praktischen Berechnung der Kovarianz mittels der Formel $s_{xy} = \frac{\sum (x_i - \bar{x}) \cdot (y_i - \bar{y})}{n}$ macht der Zähler ziemlich viel Arbeit. Der Rechenaufwand halbiert sich fast, wenn man folgende Gleichung ausnutzt:

$$\sum (x_i - \bar{x}) \cdot (y_i - \bar{y}) = \left(\sum x_i \cdot y_i \right) - n \cdot \bar{x} \cdot \bar{y}$$

Rechnen Sie nach, dass diese Gleichung stimmt. (3)

Tipp: Es ist $\sum x_i = n \cdot \bar{x}$, analog für $\sum y_i$.

2. Es besteht ein Zusammenhang zwischen der Wasseroberflächentemperatur X (in $^{\circ}\text{C}$) des Meeres und der Verdunstung Y (Class-A-Kessel, mm pro Tag). Verbundene Messungen in den sieben Monaten April bis Oktober eines Jahres ergaben folgende Daten:

Temperatur X [$^{\circ}\text{C}$]	9,1	15,9	18,7	22,1	19,2	15,8	11,2
Verdunstung Y [$\text{mm}\cdot\text{d}^{-1}$]	2,0	3,2	3,6	3,8	2,5	1,6	0,8

- a) Visualisieren Sie die Punkte $(x_i | y_i)$ in einem x - y -Koordinatensystem (Maßstab X -Achse: 1 Kästchen = 1°C , Y -Achse: 5 Kästchen = $1 \text{ mm}\cdot\text{d}^{-1}$). (1)
- b) Aufgrund welcher Kriterien darf aus der Punktwolke auf lineare Korreliertheit von X und Y geschlossen werden? (1)
- c) Berechnen Sie die Ausgleichsgerade $\tilde{Y} = A + B \cdot X$ (Drei-Schritt-Verfahren, A und B mit 2 Nachkommastellen) und zeichnen Sie sie in die Skizze aus a) ein. (4)
- d) Berechnen Sie den Korrelationskoeffizienten r (4 Nachkommastellen). Liegt eine starke oder schwache lineare Korrelation vor? (3)

3. Gegeben sei eine verbundene Messreihe zu den Variablen X, Y :

\bar{X}	x_1	...	x_n
\bar{Y}	y_1	...	y_n

- a) Bildet man die Vektoren $\vec{a} = (x_1 - \bar{x}, x_2 - \bar{x}, \dots, x_n - \bar{x})$ und $\vec{b} = (y_1 - \bar{y}, y_2 - \bar{y}, \dots, y_n - \bar{y})$, so gilt für den Winkel α zwischen diesen beiden Vektoren stets:

$$\cos \alpha = r \text{ (Korrelationskoeffizient von Pearson).}$$

Rechnen Sie nach, dass diese Gleichung stimmt. (1)

- b) Die stärkstmögliche lineare Korrelation besteht, wenn alle Punkte $(x_i | y_i)$ genau auf der Ausgleichsgeraden $\tilde{Y} = A + B \cdot X$ liegen, d.h. wenn nicht nur, wie stets, $\bar{y} = A + B \cdot \bar{x}$ gilt, sondern auch $y_i = A + B \cdot x_i$ für alle $i = 1, \dots, n$. Rechnen Sie nach, dass dann sogar gilt:
 $r = 1$, falls die Steigung B positiv ist, und $r = -1$, falls die Steigung B negativ ist. (3)

Bedingungen für die erfolgreiche Teilnahme:

- Regelmäßige Teilnahme an der Vorlesung (maximal 2 mal Fehlen).
- Auf mindestens 9 Übungsblätter jeweils mindestens 5 Punkte erhalten, insgesamt jedoch mindestens 75 Punkte. Es sind 11 Übungsblätter mit jeweils mindestens 15 Punkten geplant.
- Dazu das Bestehen einer Klausur.

Klausurtermine:

1. Klausur: Do, 19.07.12, 11:00 – 12:45, Hörsaalgebäude Chemie Lahnberge, Hans-Meerwein-Str., HS A + B
2. Klausur: Do, 11.10.12, 11:00 – 12:45, Hörsaalgebäude Chemie Lahnberge, Hans-Meerwein-Str., HS B

Bezeichnungen:

$$\begin{aligned} \text{Varianz von X} & \quad s_x^2 = \frac{\sum (x_i - \bar{x})^2}{n} \\ \text{Varianz von Y} & \quad s_y^2 = \frac{\sum (y_i - \bar{y})^2}{n} \\ \text{Kovarianz von X und Y} & \quad s_{xy} = \frac{\sum (x_i - \bar{x}) \cdot (y_i - \bar{y})}{n} \end{aligned}$$

Alternative Berechnungsformeln (siehe Aufgabenblatt 3, Nr. 2, und Aufgabe Nr. 1 oben):

$$\begin{aligned} \text{Varianz von X} & \quad s_x^2 = \frac{\sum x_i^2 - n \cdot \bar{x}^2}{n} \\ \text{Varianz von Y} & \quad s_y^2 = \frac{\sum y_i^2 - n \cdot \bar{y}^2}{n} \\ \text{Kovarianz von X und Y} & \quad s_{xy} = \frac{\sum x_i \cdot y_i - n \cdot \bar{x} \cdot \bar{y}}{n} \end{aligned}$$

Lineare Regression

Gegeben n verbundene Messungen (x_i, y_i) zweier Variabler X und Y . Visualisierung der Daten zeige, dass die Punkte $(x_i | y_i)$ ($i = 1, 2, \dots, n$), ungefähr auf einer steigenden oder fallenden Geraden liegen oder in einer Punktwolke mit bandartiger Optik, welche ungefähr geradlinig steigt oder fällt.

Die **Ausgleichsgerade** oder **Regressionsgerade** $\tilde{Y} = A + B \cdot X$ zur Messreihe ist dadurch eindeutig charakterisiert, dass für sie der Abstand zwischen der empirischen Datenzeile (y_1, \dots, y_n) und der theoretischen Datenzeile $(A+B \cdot x_1, \dots, A+B \cdot x_n)$ minimal wird.

Berechnung der Konstanten A, B in der Formel $\tilde{Y} = A + B \cdot X$ (**Drei-Schritt-Verfahren**):

$$\begin{aligned} 1. \text{ Schritt: Berechne die Mittelwerte} & \quad \bar{x} = \frac{\sum x_i}{n} \text{ und } \bar{y} = \frac{\sum y_i}{n}, \\ & \quad \text{die Quadratsumme } \sum x_i^2 \text{ und} \\ & \quad \text{die Produktsumme } \sum x_i \cdot y_i \end{aligned}$$

$$2. \text{ Schritt: Berechne die Steigung der Geraden } B = \frac{\sum x_i \cdot y_i - n \cdot \bar{x} \cdot \bar{y}}{\sum x_i^2 - n \cdot \bar{x}^2}. \quad \text{Es gilt hiermit } B = \frac{s_{xy}}{s_x^2}.$$

$$3. \text{ Schritt: Nach dem Runden von } B \text{ berechne den Schnittpunkt mit der senkrechten Achse } A = \bar{y} - B \cdot \bar{x}.$$

Bemerkung: Die Ausgleichsgerade verläuft durch die zwei Punkte $(0 | A)$ und $(\bar{x} | \bar{y})$.

Soll die Ausgleichsgerade eine Proportionalität modellieren, also durch den Ursprung verlaufen, so **muss** man für den Schnittpunkt mit der senkrechten Achse a priori $A = 0$, d.h. also $\bar{y} - B \cdot \bar{x} = 0$ fordern. Das bedeutet eine **Zusatzbedingung** an die Steigung der Geraden. ^{Daraus} ergibt sich eine geänderte

$$\text{Berechnung der Ursprungsgeraden } \tilde{Y} = C \cdot X \text{ (Ein-Schritt-Verfahren):} \quad C = \frac{\sum x_i \cdot y_i}{\sum x_i^2}$$

Korrelationskoeffizient r (aussagekräftig nur bei vorliegender linearer Korrelation von X und Y)

$$r = \frac{\sum (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \cdot \sqrt{\sum (y_i - \bar{y})^2}} \quad \text{oder auch} \quad r = \frac{\sum x_i \cdot y_i - n \cdot \bar{x} \cdot \bar{y}}{\sqrt{\sum x_i^2 - n \cdot \bar{x}^2} \cdot \sqrt{\sum y_i^2 - n \cdot \bar{y}^2}}$$

Winkelrechnung im \mathbb{R}^n

Sind $\vec{a} = (a_1, \dots, a_n)$ und $\vec{b} = (b_1, \dots, b_n)$ zwei beliebige Vektoren der Länge $\|\vec{a}\| = \sqrt{\sum a_i^2}$ und $\|\vec{b}\| = \sqrt{\sum b_i^2}$ mit dem Skalarprodukt $\vec{a} \cdot \vec{b} = \sum a_i \cdot b_i$, so gilt für den Winkel α zwischen den beiden Vektoren allgemein:

$$\cos \alpha(\vec{a}, \vec{b}) = \frac{\vec{a} \cdot \vec{b}}{\|\vec{a}\| \cdot \|\vec{b}\|}.$$

Dieser verallgemeinerte Kosinus hat immer einen Wert zwischen -1 und 1 . Er ist $= 1$ bzw. $= -1$, wenn die Vektoren sich nur durch einen positiven bzw. negativen skalaren Faktor unterscheiden.