

# Musterlösung zur Testklausur Statistik

WMS17A (Oettinger, 2018)

## Aufgabe 1

- (a) Richtig: das arithmetische Mittel reagiert im Gegensatz zum Median empfindlich auf Ausreißer.
- (b) Falsch: ein ordinales Merkmal besitzt eine natürliche Rangfolge, ein nominales Merkmal keine.
- (c) Richtig: es handelt sich um eine Summe quadrierter Größen.
- (d) Falsch: der Modus ist die am häufigsten auftretende Merkmalsausprägung in einer Stichprobe.
- (e) Falsch: es handelt sich um ein mittleres Wachstum, es kann auch negativ sein.

## Aufgabe 2

Die Tabelle in Form relativer Häufigkeiten:

$X$ (PKW)	1	2	3	4	$\Sigma$
Verbrauch $Y$					
6,1	0,182	0,2	0,182	0,194	0,185
6,2	0,545	0,6	0,545	0,516	0,546
6,3	0,273	0,2	0,273	0,290	0,269
$\Sigma$	1	1	1	1	1

- (a) Die Spalten der Tabelle relativer Häufigkeiten unterscheiden sich  $\implies$  die Größen  $X$  und  $Y$  sind nicht stochastisch unabhängig.
- (b) Die bedingte Verteilung  $f(x_i|Y = 6,2)$  besteht aus den relativen Häufigkeiten der Zeile mit  $Y = 6,2$ , also

$$f(x_i|Y = 6,2) = \left\{ \frac{6}{124}; \frac{12}{124}; \frac{90}{124}; \frac{9}{124} \right\}.$$

(c) Benötigt wird der Mittelwert des Verbrauchs für PKW 2 (alle Angaben in l):

$$\bar{y}(X = 2) = \frac{1}{20} (4 \cdot 6,1 + 12 \cdot 6,2 + 4 \cdot 6,3) = 6,2.$$

Die Varianz ist die mittlere quadratische Abweichung vom Mittelwert, also

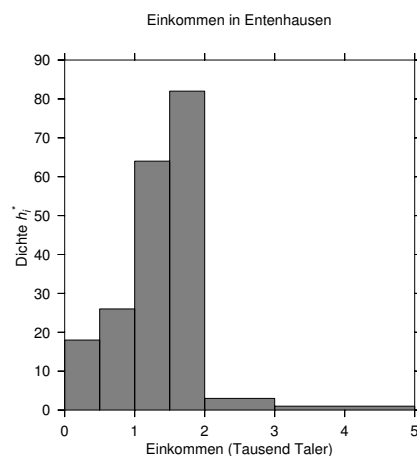
$$\begin{aligned} s^2(Y|X = 2) &= \frac{1}{20} (4 \cdot (6,1 - 6,2)^2 + 12 \cdot (6,2 - 6,2)^2 + 4 \cdot (6,3 - 6,2)^2) \\ &= \frac{1}{20} 8 \cdot 0,1^2 = 4 \cdot 10^{-3}. \end{aligned}$$

### Aufgabe 3

a) Die benötigten Daten:

Einkommen in Talern	Klassenbreite in Tausend Talern	Häufigkeit	relativ	kumuliert	Dichte
]0-500]	0,5	9	0,09	0,09	18
]500-1000]	0,5	13	0,13	0,22	26
]1000-1500]	0,5	32	0,32	0,54	64
]1500-2000]	0,5	41	0,41	0,95	82
]2000-3000]	1,0	3	0,03	0,98	3
]3000-5000]	2,0	2	0,02	1,0	1

Histogramm der Einkommen:



**Abbildung 1:** Einkommensverteilung in Entenhausen

b) arithmetisches Mittel (in Tausend Taler):

$$\bar{x} = \frac{1}{100}(0,25 \cdot 9 + 0,75 \cdot 13 + 1,25 \cdot 32 + 2,5 \cdot 3 + 4,0 \cdot 2) = \frac{139,25}{100} = 1,39$$

50% der befragten Personen werden in der 3.Klasse erreicht, der Median (in Tausend Taler) ist

$$F(\bar{x}_Z) = x_3^u + (x_3^o - x_3^u) \frac{F(\bar{x}_Z) - F(x_3^u)}{F(x_3^o) - F(x_3^u)} = x_3^u + (x_3^o - x_3^u) \frac{F(0,5) - F(x_3^u)}{F(x_3^o) - F(x_3^u)}$$

$$1 + (1,5 - 1) \cdot \frac{0,5 - 0,22}{0,54 - 0,22} = 1,44.$$

Der Median ist etwas größer - die Verteilung scheint leicht rechtssteil.

c) Für die Lorenzkurve wird das gesamte Einkommen benötigt (in Tausend Talern):


$$g_{ges} = 0,25 \cdot 9 + 0,75 \cdot 13 + 1,25 \cdot 32 + 2,5 \cdot 3 + 4,0 \cdot 2 = 139,25$$

Jetzt kann der Anteil der Personen in jeder Klasse am Gesamteinkommen berechnet werden:

$$q_k = f_k \cdot (x_k^o + x_k^u)/2.$$

Einkommen in Talern	relative Häufigkeit $f_k$	kumuliert $F_k$	Anteil $q_k$	kumuliert $Q_k$
]0-500]	0,09	0,09	0,032	0,032
]500-1000]	0,13	0,22	0,070	0,102
]1000-1500]	0,32	0,54	0,287	0,389
]1500-2000]	0,41	0,95	0,515	0,904
]2000-3000]	0,03	0,98	0,054	0,958
]3000-5000]	0,02	1,0	0,057	1

Lorenz-Plot:



**Abbildung 2:** Lorenzkurve der Einkommensverteilung in Entenhausen

Der Gini-Koeffizient entspricht der doppelten Fläche zwischen den beiden Kurven. Man erkennt, dass die relative Konzentration (und damit der Gini-Koeffizient) nicht besonders groß ist.

#### Aufgabe 4

An einer neu gegründeten Universität sollen 6-stellige Matrikelnummern vergeben werden. Berechnung unter der vereinfachenden Annahme, dass auch 000000 als Matrikelnummer zulässig sein soll:

- (a) Anzahl  $A$  aller möglichen Kombinationen für 6-stellige Matrikelnummern: Jede Stelle kann mit  $0 \dots 9$  besetzt werden.  $A = 10^6$  (unter der Annahme, dass auch 000000 als Matrikelnummer zählt).
- (b) Soll keine Nummer mit einer Null beginnen, gibt es für die erste Stelle nur 9 Möglichkeiten ( $1 \dots 9$ ).  $A = 9 \cdot 10^5$ .
- (c) Keine Ziffer soll zweimal vorkommen (Berechnung unter der Annahme, dass eine führende Null erlaubt ist): für die erste Stelle gibt es 10 Möglichkeiten, für die zweite 9, für die dritte 8 usw.  
 $A = 10 \cdot 9 \cdot 8 \cdot 7 \cdot 6 \cdot 5 = 151200$

## Aufgabe 5

Die Aussage des Herrn Trumpet kann durch Vergleich der Variationskoeffizienten überprüft werden. Benötigt werden die arithmetischen Mittel (in %)

$$\bar{x}_A = \frac{1}{7} (5,6 + 6,3 + 6,6 + 6,9 + 7,1 + 7,6 + 6,1) = 6,6$$

$$\bar{x}_B = \frac{1}{7} (40,4 + 41,9 + 47,9 + 40,4 + 48,9 + 41,4 + 42,9) = 43,4$$

sowie die Varianzen und die daraus berechneten Standardabweichungen

$$s_A^2 = \frac{1}{7} (5,6^2 + 6,3^2 + 6,6^2 + 6,9^2 + 7,1^2 + 7,6^2 + 6,1^2) - 6,6^2$$

$$= 0,383$$

$$\Rightarrow s_A = \sqrt{s_A^2} = 0,619$$

$$s_B^2 = \frac{1}{7} (40,4^2 + 41,9^2 + 47,9^2 + 40,4^2 + 48,9^2 + 41,4^2 + 42,9^2) - 43,4^2$$

$$= 10,714$$

$$\Rightarrow s_B = \sqrt{s_B^2} = 3,273.$$

Die Variationskoeffizienten  $v_x = \frac{s_x}{\bar{x}}$  für die beiden Stichproben sind

$$v_A = \frac{s_A}{\bar{x}_A} = \frac{0,619}{6,6} = 0,094$$

und

$$v_B = \frac{s_B}{\bar{x}_B} = \frac{3,273}{43,4} = 0,075.$$

Damit wird klar, dass Herr Trumpet falsch liegt, die Verteilung der Stimmenanteile für seine Partei  $A$  ist deutlich breiter.

## Aufgabe 6

- (a) die mittlere erreichte Geschwindigkeit ergibt sich ganz einfach, indem die gesamte zurückgelegte Strecke durch die gesamte benötigte Zeit geteilt wird (Geschwindigkeit in km/h):

$$\bar{v} = \frac{1 \cdot 7 + 5}{1 + 1,25} = 5,3$$

(b) Der Mittelwert berechnet sich nach

$$\bar{x} = \frac{1}{20}(5 \cdot 1 + 11 \cdot 2 + 3 \cdot 3 + 4) = 2,0$$

Für die Kandidaten, die nicht bestanden haben, kann keine Note angegeben werden, sie werden zur Berechnung *nicht* herangezogen.

(c) Geometrisches Mittel:

$$\bar{x}_G = \sqrt{1,56 \cdot 1,04} - 1 = 0,274 \text{ oder } 27,4\%$$

(d) Wiederum geometrisches Mittel:

$$\bar{x}_G = \sqrt{2 \cdot 2} - 1 = 2 - 1 = 1 \text{ oder } 100\%,$$

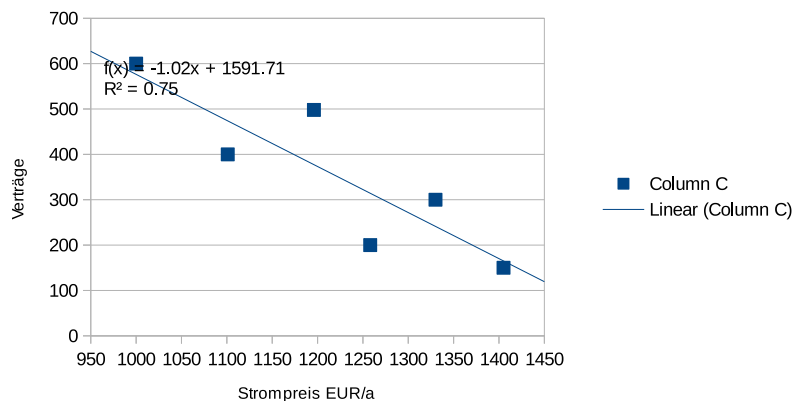
genau das ist ja die Aussage (verdoppelt sich jede Nacht!).

(e)

$$\bar{x}_G = \sqrt{2 \cdot 8} - 1 = 4 - 1 = 3 \text{ oder } 300\%.$$

## Aufgabe 7

a) Daten mit Ausgleichsgerade



Anpassung einer Geraden  $y = a \cdot x + b$  über lineare Regression: die arithmetischen Mittel sind  $\bar{x} = 1215$  und  $\bar{y} = 358$ , die Tabelle der benötigten Daten

Preis	Verträge	$(x_i - \bar{x})$	$(y_i - \bar{y})$	$(x_i - \bar{x})(y_i - \bar{y})$	$(x_i - \bar{x})^2$	$(y_i - \bar{y})^2$
1000	600	-215	242	-52030	46225	58564
1101	400	-114	42	-4788	12996	1764
1196	498	-19	140	-2660	361	19600
1258	200	43	-158	-6794	1849	24964
1330	300	115	-58	-6670	13225	3364
1405	150	190	-208	-39520	36100	43264

Die Steigung der Geraden ist

$$a = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = -1,02$$

der Achsenabschnitt ist

$$b = \bar{y} - a\bar{x} = 1591,71$$

- b) Die erwartete Zahl der Verträge ist bei einem linearen Zusammenhang von  $y = 1591,71 - 1,02 \cdot x$

$$y(1200) = 367,71.$$

Es werden also etwa 368 Verträge erwartet.

- c) der Pearson-Koeffizient ist

$$r_{xy} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

$$= \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} = -0,87 \quad (2)$$

Der Wert nahe eins legt einen relativ guten linearen Zusammenhang zwischen den Daten nahe.

## Aufgabe 8

1. Studierende der DHBW in Ravensburg: Bestandsmasse.
2. Todesfälle in einer Gemeinde: Bewegungsmasse.
3. Maschinenausfälle in einer Werkstatt: Bewegungsmasse.
4. Die Bevölkerung in Ravensburg zum 1.9.2010: Bestandsmasse.