

Musterlösung zur Übungsklausur Statistik

WMS15B

Oettinger 9/2016

Aufgabe 1

- (a) Falsch: der Modus ist die am häufigsten auftretende Merkmalsausprägung in einer Stichprobe.
- (b) Falsch: die beiden Größen sind voneinander unabhängig - sie können gleich sein, müssen aber nicht.
- (c) Richtig: es handelt sich um eine Summe positiver Abweichungen.
- (d) Richtig: es kann als mittlerer Wert nur kleiner als das Maximum sein.
- (e) Ein Merkmal ist entweder metrisch oder stetig, d.h. es gibt kein Merkmal, das gleichzeitig metrisch und stetig ist - falsch, ein stetiges Merkmal ist immer auch metrisch (Zahlen!).

Aufgabe 2

- (a) Jede Antwort ist zulässig
- (b) Statistische Einheit sind Giovannis Kunden, Merkmale sind Speisen und Getränke. Die Merkmalsausprägungen sind die vom Kunden bestellten Gerichte und Getränke, beispielsweise 'Rotwein' oder 'Pizza'.
- (c) Darstellung der Daten im Stab- oder Balkendiagramm. Grafik nicht gefordert!




Abbildung 1: Stabdiagramm als Beispiel für die grafische Darstellung

- (d) Ereignis A : Kunde bestellt Spaghetti, $P(A) = 0,6$.
 Ereignis B : Kunde bestellt Rotwein, $P(B) = 0,7$.
 Ereignis C : Kunde bestellt Spaghetti und Rotwein, $P(C) = P(A) \cdot P(B) = 0,6 \cdot 0,7 = 0,42 = 42\%$.
 Ereignis D : Kunde bestellt Spaghetti, aber keinen Rotwein, $P(D) = P(A) \cdot (1 - P(B)) = 0,6 \cdot (1 - 0,7) = 0,6 \cdot 0,3 = 0,18 = 18\%$.
- (e) Die relative Häufigkeit für eine Spaghettlänge größer als 80cm ist $0,15 + 0,05 = 0,2 = 20\%$.
 Das arithmetische Mittel (in cm) muss mit den Klassenmitten gerechnet werden (wegen der Angabe relativer Häufigkeiten wird nicht durch die Gesamtzahl geteilt):

$$\bar{x} = 0,15 \cdot 30 + 0,25 \cdot 50 + 0,40 \cdot 70 + 0,15 \cdot 90 + 0,05 \cdot 115 = 64,25$$

- (f) Der Median (in cm) entfällt auf die 3.Klasse $]60; 80]$:

$$\begin{aligned} \bar{x}_Z &= x_3^u + (x_3^o - x_3^u) \cdot \frac{F(\bar{x}_Z) - F(x_3^u)}{F(x_3^o) - F(x_3^u)} \\ &= 60 + (80 - 60) \cdot \frac{0,5 - 0,4}{0,8 - 0,4} = 65. \end{aligned}$$

- (g) Da die Klassen unterschiedlich breit sind, wird die Dichte der relativen Häufigkeiten aufgetragen. Daten zur grafischen Darstellung:

Länge (cm)	Klassenbreite (in m) Δ_k	rel. Häufigkeit f_k	Dichte $f_k^* = \frac{f_k}{\Delta_k}$
(20; 40]	0,20	0,15	0,75
(40; 60]	0,20	0,25	1,25
(60; 80]	0,20	0,4	2,0
(80; 100]	0,20	0,15	0,75
(100; 130]	0,30	0,05	0,167




Abbildung 2: Histogramm der Verteilung der Nudellänge

Aufgabe 3

Die Tabelle in Form relativer Häufigkeiten:

X (PKW)	1	2	3	4	Σ
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
Σ	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 $f(x_i|Y = 6,2)$ ist die Zeile mit $Y = 6,2$, also $f(x_i|Y = 6,2) = \{6; 12; 90; 9\}$.

(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 4

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 3: 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 4: 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 5

1. Harmonisches Mittel:

$$\bar{x}_H = \frac{7}{\frac{1}{15} + \frac{1}{16,5} + \frac{1}{17,5} + \frac{1}{18} + \frac{1}{18} + \frac{1}{20} + \frac{1}{22}} = 17,9037$$

2. Die Durchschnittsgeschwindigkeit erhält man als Quotienten der gesamten zurückgelegten Strecke und der gesamten benötigten Zeit, also

$$\frac{15km + 16,5km + 17,5km + 18km + 18km + 20km + 22km}{7h}$$

Die Anwendung des arithmetischen Mittels ist hier korrekt.

1. 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!).

2.

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

3. Eine Stunde 50 km/h, 1 Stunde und 15 Minuten 40 km/h.
Die Gesamtzeit sind 2 Stunden und 15 Minuten, die zurückgelegte Strecke $s = 1\text{h} \cdot 50\text{km/h} + 1,25\text{h} \cdot 40\text{km/h} = 100\text{km}$.
Durchschnittsgeschwindigkeit in km/h:


$$\bar{v} = \frac{100}{2,25} = 44,4.$$

Das ist das harmonische Mittel der Geschwindigkeiten (in km/h):

$$\bar{v} = \frac{1}{1/2(\frac{1}{50} + \frac{1}{40})} = 44,4$$

Aufgabe 6

a) Daten mit Ausgleichsgerade



b) Anpassung einer Geraden $y = a \cdot x + b$ über lineare Regression: Tabelle benötigter 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

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

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.