

# Klausur Statistik

## Lösungshinweise

Prüfungsdatum: 5. Juli 2017 – Prüfer: Etschberger, Ivanov, Jansen, Wesp, Wins  
 Studiengang: IM, BW, Inf und W-Inf  
 Punkte: 18, 16, 14, 10, 9, 15, 8 ; Summe der Punkte: 90

### Aufgabe 1

18 Punkte

Eine Studie bei 100 Absolventen einer Hochschule ergab für das Merkmal  $X \hat{=} \text{„Studiendauer in Semestern“}$  für die Ausprägungen  $a_i$ , die absoluten Häufigkeiten  $h_i$ , die kumulierten relativen Häufigkeiten  $u_i$  sowie dem kumulierten Merkmalssummenanteil  $v_i$  mit

$$u_i = \sum_{k=1}^i f_k, \quad v_i = \frac{\sum_{k=1}^i a_k \cdot h_k}{\sum_{k=1}^n a_k \cdot h_k}$$

folgende unvollständige Tabelle:

$i$	1	2	3	4	5	6	7
$a_i$	4	6	7	8	10	20	40
$h_i$	10	10	20	20	28	8	4
$u_i$	0.10	0.20	0.40	0.60	0.88	0.96	1.00
$v_i$	0.04	0.10	0.24	0.40	0.68	0.84	1.00

Außerdem ist das arithmetische Mittel des Merkmals mit  $\bar{x} = 10$  bekannt.

a) Füllen Sie die fehlenden Felder in der Tabelle aus.

(Hinweis: Wenn Sie die Teilaufgabe a) nicht lösen können, rechnen Sie mit den (falschen) Werten  $a_4 = 9.5, h_4 = 37$  weiter)

b) Bestimmen Sie den Median, das empirische 25 % sowie das 75 % Quantil des Merkmals.

c) Zeichnen Sie einen Boxplot zu diesen Daten.

**R** d) Nehmen Sie an, die Daten des Merkmals  $X$  sind im R-Vektor  $x$  gespeichert. Schreiben Sie in das folgende Kästchen R-Befehle, mit denen Sie die Teilaufgaben b) und c) lösen können:


```
quantile(x, probs = c(0.25, 0.5, 0.75), type=2)
boxplot(x)
```

### Lösungshinweis:

a) S.o.

```
b) quantile(x, probs = c(0.25, 0.5, 0.75),
           type=3)
## 25% 50% 75%
##    7  8  10
```

c) `boxplot(x)`



d) s.o.

## Aufgabe 2

16 Punkte

Für 180 Zugverbindungen wurden zwei Merkmale erhoben:

- ▶ der Wochentag der Abfahrt als „*Tag*“ mit den beiden Ausprägungen *Montag - Freitag* bzw. *Samstag oder Sonntag*
- ▶ die Differenz zur geplanten Abfahrtszeit als „*Verspätung*“

Hieraus ergab sich folgende unvollständige Kontingenztabelle:

Tag	Verspätung			Summe
	pünktlich	1-15 Min.	> 15 Min.	
Montag - Freitag	58	46	16	120
Samstag, Sonntag	32	14	14	60
Summe	90	60	30	180

Es sei zudem bekannt, dass insgesamt  $\frac{2}{3}$  der Züge an Arbeitstagen (Mo-Fr) abgefahren sind und zudem 50 % aller Züge pünktlich abgefahren sind.


- Ergänzen Sie die obige Kontingenztabelle sowie deren Randhäufigkeiten.
- In R seien mit den beiden Merkmalsvektoren  $T$  (Tag) und  $V$  (Verspätung) die 180 individuellen Ausprägungen gegeben. Geben Sie R-Befehle an, die die Kontingenztabelle und deren Randhäufigkeiten ausgeben.
- Zeigen Sie – ohne die Bestimmung eines Zusammenhangsmaßes – dass die beiden Merkmale *Tag* und *Verspätung* nicht unabhängig sind.
- Aus der Kontingenztabelle ergibt sich  $\chi^2 = 5.3$  (Diesen Wert müssen Sie *nicht* nachrechnen). Bestimmen Sie damit den normierten Kontingenzkoeffizienten und interpretieren Sie diesen.

In einer anderen Untersuchung wurde bei 1000 Zugverbindungen die Verspätung zur geplanten Abfahrtszeit (Merkmal: *Abfahrt* [in Minuten]) sowie die Verspätung zur geplanten Ankunftszeit an der Endstation (Merkmal: *Endstation* [in Minuten]) untersucht. Es wird ein linearer Zusammenhang vermutet, der mittels Regression untersucht werden soll. Die erhobenen Daten seien in einem R-Dataframe mit dem Bezeichner *Verspaetungen* gespeichert. Für das Regressionsmodell ergibt sich demnach:

```
lm(Endstation ~ Abfahrt, data=Verspaetungen)

##
## Call:
## lm(formula = Endstation ~ Abfahrt, data = Verspaetungen)
##
## Coefficients:
## (Intercept)      Abfahrt
##      5.840         1.425
```

- R e) Geben Sie den Funktionsterm der Regressionsgerade an und zeichnen Sie diese in den nebenstehenden Streuplot der Daten ein.
- R f) Ein Zug fährt mit 5 Minuten Verspätung ab. Wieviel würde sich gemäß dem Regressionsmodell die Ankunftszeit verspäten?
- R g) Geben Sie R-Befehle an, mit denen Sie ein geeignetes Streudiagramm mit der farblich eingezeichneten Regressionsgeraden erzeugen können.



### Lösungshinweis:

a) siehe oben

```
b) Tabelle = table(T, V)
addmargins(Tabelle)
```

```
##      V
## T      puenktlich [1; 15] >15 Sum
## Mo-Fr          58      46  16 120
## Sa,So          32      14  14  60
## Sum            90      60  30 180
```

c) Betrachte z.B. Mo-Fr/pünktlich:  $120 \cdot 90/180 = 60 \neq 58$

d)  $K = \sqrt{\frac{\chi^2}{\chi^2 + n}} = \sqrt{\frac{5.3}{5.3 + 180}} = 0.169122$ .  $K_{\max} = \sqrt{\frac{2-1}{2}} = \sqrt{0.5}$ .

e)  $\hat{y} = 5.8399929 + 1.4245971 \cdot x$

f)  $\hat{y}(5) = 12.9629785$

```
g) V.Reg = lm(Endstation ~ Abfahrt, data=Verspaetungen)
plot(Abfahrt, Endstation)
abline(V.Reg, col="blue")
```

### Aufgabe 3

14 Punkte

Leonard, Sheldon, Howard und Raj spielen ein Brettspiel. Dazu haben sie insgesamt fünf faire Würfel in Form der fünf platonischen Körper:

- ▶ Würfel A ist ein 4-seitiger mit den Zahlen 1 bis 4,
- ▶ Würfel B ein 6-seitiger mit den Zahlen 1 bis 6,
- ▶ Würfel C ein 8-seitiger mit den Zahlen 1 bis 8,
- ▶ Würfel D ein 12-seitiger mit den Zahlen 0 bis 9 sowie je einer weiteren Seite mit den Zahlen 1 und 2,
- ▶ Würfel E ein 20-seitiger Würfel, der zweimal die Zahlen 0 bis 9 hat.

- a) Leonard würfelt die Würfel in der Reihenfolge von A bis E. Wie viele verschiedene Ausgänge gibt es?
- b) Raj würfelt alle Würfel gleichzeitig. Wie groß ist die Wahrscheinlichkeit dafür, dass alle Würfel eine 1 zeigen?
- c) Sheldon bekommt zufällig zwei der drei Würfel A, B und C und würfelt diese. Wie groß ist die Wahrscheinlichkeit, dass beide Würfel eine 1 zeigen?
- d) Howard wirft 7 mal Würfel C. Er interessiert sich für die Wahrscheinlichkeit  $p$ , dass er mindestens 3 mal eine Zahl wirft, die größer als 4 ist. Geben Sie einen R-Ausdruck an, mit dem  $p$  berechnet werden kann.  
(Hinweis: Die Wahrscheinlichkeit müssen Sie nicht berechnen.)

R

### Lösungshinweis:

a)  $4 \cdot 6 \cdot 8 \cdot 10 \cdot 10 = 19200$

b) Man multipliziert die Wahrscheinlichkeiten aller Würfel für eine 1. Es ergibt sich:

$$P = \frac{1}{4} \cdot \frac{1}{6} \cdot \frac{1}{8} \cdot \frac{2}{12} \cdot \frac{2}{20} = \frac{4}{46080} = \frac{1}{11520} \approx 8,68055 \cdot 10^{-5}$$

c) Die Kombinationen AB, AC oder BC werden mit je  $1/3$  Wahrscheinlichkeit ausgewählt.

$$P = \frac{1}{3} \left( \frac{1}{4} \cdot \frac{1}{6} + \frac{1}{4} \cdot \frac{1}{8} + \frac{1}{6} \cdot \frac{1}{8} \right) = \frac{1}{32} = 0,03125$$

d)  $X =$  „Anzahl größer als 4“;  $X \sim B(n = 7, p = 0.5)$

```
1 - pbinom(q = 2, size = 7, prob = 0.5)
```

```
## [1] 0.7734375
```

## Aufgabe 4

10 Punkte

Gegeben sei eine Zufallsvariable  $X$  mit  $X \sim B(3000; 0.001)$ .

a) Berechnen Sie

(1)  $P(X \geq 3 | X \leq 1)$

(2)  $P(X \geq 1 | X \leq 3)$

(3)  $P(X \leq 1 | X \leq 3)$

(4)  $P(X \leq 3 | X \leq 1)$

**R** b) Geben Sie eine R-Zeile an, der die Lösung von Teilaufgabe a), (2) ausgibt.

### Lösungshinweis:

a) (1)  $P(X \geq 3 | X \leq 1) = 0$

(2)  $P(X \geq 1 | X \leq 3) = \frac{P(X \in \{1, 2, 3\})}{P(X \leq 3)} = \frac{0.5975195}{0.6472319} = 0.9231923$

(3)  $P(X \leq 1 | X \leq 3) = \frac{0.1989989}{0.6472319} = 0.3074615$

(4)  $P(X \leq 3 | X \leq 1) = 1$

b) `(sum(dbinom(x=1:3, p=0.001, size=3000)))/pbinom(3, p=0.001, size=3000)`

```
## [1] 0.9231923
```

Für eine einfache Stichprobe  $X_1, X_2$  mit  $E[X_i] = \mu$  und  $\text{Var}[X_i] = \sigma^2$  (für  $i = 1, 2$ ) sollen Stichprobenfunktionen zum Schätzen des arithmetischen Mittels der Grundgesamtheit untersucht werden. Zur Diskussion stehen drei Funktionen  $\hat{\Theta}_1, \hat{\Theta}_2, \hat{\Theta}_3$ :

$$\hat{\Theta}_1 = 0.5 \cdot X_1 + 0.5 \cdot X_2$$

$$\hat{\Theta}_2 = 0.4 \cdot X_1 + 0.6 \cdot X_2$$

$$\hat{\Theta}_3 = a_1 \cdot X_1 + a_2 \cdot X_2 \quad (a_1, a_2 \geq 0)$$

- Zeigen Sie, dass  $\hat{\Theta}_1$  und  $\hat{\Theta}_2$  erwartungstreue Schätzer für  $\mu$  sind.
- Welche Schätzfunktion ist wirksamer:  $\hat{\Theta}_1$  oder  $\hat{\Theta}_2$ ?
- Zeigen Sie, dass  $\hat{\Theta}_3$  genau dann erwartungstreu ist, wenn  $a_1 + a_2 = 1$  gilt.
- Für welche Werte von  $a_1, a_2$  ist  $\hat{\Theta}_3$  am wirksamsten?

### Lösungshinweis:

$$\text{a) } E[\hat{\Theta}_1] = E[0.5 \cdot X_1 + 0.5 \cdot X_2] = 0.5 \cdot E[X_1] + 0.5 \cdot E[X_2] = 0.5 \cdot \mu + 0.5 \cdot \mu = \mu$$

$$E[\hat{\Theta}_2] = E[0.4 \cdot X_1 + 0.6 \cdot X_2] = 0.4 \cdot E[X_1] + 0.6 \cdot E[X_2] = 0.4 \cdot \mu + 0.6 \cdot \mu = \mu$$

$$\text{b) } \text{Var}[\hat{\Theta}_1] = \text{Var}[0.5 \cdot X_1 + 0.5 \cdot X_2] = 0.5^2 \cdot \text{Var}[X_1] + 0.5^2 \cdot \text{Var}[X_2]$$

$$= 0.25 \cdot \sigma^2 + 0.25 \cdot \sigma^2 = 0.5 \cdot \sigma^2$$

$$\text{Var}[\hat{\Theta}_2] = \text{Var}[0.4 \cdot X_1 + 0.6 \cdot X_2] = 0.4^2 \cdot \text{Var}[X_1] + 0.6^2 \cdot \text{Var}[X_2]$$

$$= 0.16 \cdot \sigma^2 + 0.36 \cdot \sigma^2 = 0.52 \cdot \sigma^2$$

Damit ist  $\hat{\Theta}_1$  wirksamer als  $\hat{\Theta}_2$ , da  $\text{Var}[\hat{\Theta}_1] < \text{Var}[\hat{\Theta}_2]$ .

c)  $\hat{\Theta}_3$  ist erwartungstreu

$$\Leftrightarrow E[\hat{\Theta}_3] = a_1 \cdot E[X_1] + a_2 \cdot E[X_2]$$

$$= a_1 \cdot \mu + a_2 \cdot \mu = \mu$$

$$= (a_1 + a_2) \cdot \mu = \mu$$

$$\Leftrightarrow a_1 + a_2 = 1$$

$$\text{d) } \text{Var}[\hat{\Theta}_3] = a_1^2 \cdot \text{Var}[X_1] + a_2^2 \cdot \text{Var}[X_2] = (a_1^2 + a_2^2) \cdot \sigma^2$$

$\hat{\Theta}_3$  ist erwartungstreu, wenn  $a_1 + a_2 = 1 \Leftrightarrow a_2 = 1 - a_1$  und am wirksamsten, wenn

$$a_1^2 + a_2^2 = a_1^2 + (1 - a_1)^2 = a_1^2 + 1 - 2a_1 + a_1^2 = 2a_1^2 - 2a_1 + 1$$

minimal, also die Ableitung der Varianz  $V$  nach  $a_1$

$$V'(a_1) = 4a_1 - 2a_1 = 0 \quad \Leftrightarrow \quad a_1 = 0.5$$

Das ist ein globales Minimum. Damit ist  $\hat{\Theta}_3$  am wirksamsten, wenn  $a_1 = a_2 = 0.5$ .

## Aufgabe 6

15 Punkte

Eine Nagelfabrik möchte die Produktionsgenauigkeit einer Charge mit einer Solllänge von 80 mm überprüfen. Dazu werden 10 Stück Nägel aus der Produktionsanlage entnommen und deren Länge gemessen. Es ergibt sich:

Stichprobenelement Nr.	1	2	3	4	5
Länge des Nagels [in mm]	80.0	80.4	79.9	81.1	80.5
Stichprobenelement Nr.	6	7	8	9	10
Länge des Nagels [in mm]	79.9	80.6	80.7	80.6	80.2

Gehen Sie im Folgenden davon aus, dass

- ▶ die Länge der vermessenen Nägel eine einfache Stichprobe aus einer normalverteilten Grundgesamtheit aller hergestellten Nägel darstellen und
- ▶ die Urliste der Stichprobe in R in der Variable  $x$  gespeichert ist.

a) Bestimmen Sie ein Konfidenzintervall für die Länge aller Nägel in der Produktion zu einem Konfidenzniveau von 95 %.

- R** b) Schreiben Sie in folgendes Kästchen *einen* R-Befehl, mit dem man das Konfidenzintervall aus Teilaufgabe a) berechnen kann.

```
t.test(x, conf.level = 0.95)
```

c) Wie müsste die Nullhypothese  $H_0$  und die Gegenhypothese  $H_1$  lauten, wenn ein Kunde der Firma mit einem Test statistisch nachweisen möchte, dass die durchschnittliche Nagellänge in der Grundgesamtheit einer Lieferung von 1 Mio. Nägel höher als 80 cm ist?

d) Führen Sie den Test mittels der obigen Stichprobe zu einem Signifikanzniveau von  $\alpha = 1\%$  durch.

- R** e) Schreiben Sie in folgendes Kästchen *einen* R-Befehl, mit dem man den Test aus d) durchführen kann.

```
t.test(x, mu=80, alternative = "greater")
```

### Lösungshinweis:

a)  $c = x_{0,975} = 2.262, \bar{x} = 80.39, s = 0.39 \Rightarrow \left[ \bar{x} \pm \frac{sc}{\sqrt{n}} \right] = [80.111; 80.669]$

b) siehe oben

c)  $H_0$ : Arithm. Mittel der Nagellänge in GG ist 80 mm;  $H_1$ : ... ist größer 80 mm

d)  $\bar{x} = 80.39, s = 0.39, t(9) : x_{1-\alpha} = x_{0,99} = 2.821, v = \frac{\bar{x} - 80}{s} \cdot \sqrt{10} \approx 3.162.$   
 $B = (2.821; \infty)$

e) siehe oben

## Aufgabe 7

8 Punkte

Gegeben ist für  $D = \{(x, y) \in \mathbb{R}^2 : x, y > 0\}$  die Funktion  $g: D \rightarrow \mathbb{R}$  mit

$$g(x, y) = x + 4y + \frac{2}{xy}.$$

- a) Berechnen Sie die partielle Ableitung  $g_x(x, y)$  und tragen Sie das Ergebnis in das leere Feld des Gradienten von  $g$  ein:

$$\nabla g(x, y) = \begin{pmatrix} \boxed{1 - \frac{2}{x^2 y}} \\ 4 - \frac{2}{xy^2} \end{pmatrix}$$

*Hinweis: Sollten Sie Teilaufgabe a) nicht gelöst haben, benutzen Sie bitte das Ergebnis*

$$g_x(x, y) = 2y\sqrt{x} - 4 \cdot \sqrt{x^{-3}}.$$

- b) Geben Sie sämtliche kritische Punkte der Funktion  $g$  an.  
c) Ergänzen Sie die fehlenden Einträge der Hesse-Matrix  $H_g$  zu  $g$ :

$$H_g(x, y) = \begin{pmatrix} 4(yx^3)^{-1} & 2(xy)^{-2} \\ \boxed{2(xy)^{-2}} & \boxed{4(xy^3)^{-1}} \end{pmatrix}$$

- d) Setzen Sie alle kritischen Punkte aus Teilaufgabe b) in  $H_g$  ein und ermitteln Sie so Lage und Art aller Extremwerte von  $g$ .

### Lösungshinweis:

- a) Siehe oben  
b)  $x = 2, y = 1/2$   
c) siehe oben  
d)  $H(2, 1/2) = \begin{pmatrix} 1 & 2 \\ 2 & 16 \end{pmatrix} \Rightarrow 1 \cdot 16 - 2 \cdot 2 > 0$  und  $1 > 0$ , also ist der Punkt  $(x, y) = (2, 0.5)$  ein Minimum.