

# Aufgabe 1

Sie wurden von der Verbraucherschutzzentrale Bayern beauftragt, die Kunden der Ulmen Investmentbank AG zu befragen, ob diese absichtlich falsch beraten wurden. Bei der Umfrage waren 60% der Kunden über 65 Jahre. 80% der falsch beratenen Kunden waren über 65 Jahre alt. Außerdem wissen Sie, dass 30% der Kunden richtig beraten wurden.

1. Stellen Sie eine Vierfeldertafel für die Zufallsvariablen R "Person ist älter als 65" und F "Person wurde falsch beraten" auf.
2. Geben Sie folgende Wahrscheinlichkeiten an:
  - (a) Ein zufällig ausgewählter Kunde ist älter als 65 und wurde richtig beraten.
  - (b) Ein zufällig ausgewählter Kunde, der falsch beraten wurde, ist jünger als 65.
  - (c) Ein zufällig ausgewählter Kunde, der jünger als 65 ist, wurde falsch beraten.
3. Sind die beiden Zufallsvariablen R und F stochastisch unabhängig?
4. Gegeben sei die normalverteilte Zufallsvariable  $R_i$  "Jährliche logarithmierte Rendite der Schon-ewig-da-bank im  $i$ -ten Jahr", d.h.  $R_i = \ln(S_i/S_{i-1})$ , wobei  $S_i$  dem Wert des Aktienkurses am Ende des  $i$ -ten Jahres entspricht. Aufgrund der Zahlen der letzten 180 Jahre, ermitteln Sie als durchschnittliche jährliche logarithmierte Rendite  $\bar{R} = 1/180 \sum_{i=1}^{180} R_i = -0.15$ . Die Varianz ist bekannt und beträgt  $\sigma_{\bar{R}}^2 = 1.44$ .
  - (a) Ein Bekannter behauptet, dass die mittlere logarithmierte Rendite der Schon-ewig-da-bank jährlich kleiner als 0 sei. Testen Sie diese Behauptung auf dem 5% Signifikanzniveau.
  - (b) Sie kaufen trotz der Aussagen ihres Bekannten heute 10 Aktien der Schon-ewig-da-bank zum Tageskurs von 50 EUR. Mit welchem Wert ihres Investments rechnen Sie in genau einem Jahr, wenn Sie wissen, dass die tatsächliche durchschnittliche jährliche logarithmierte Rendite -0.14 beträgt? Wieviel Prozent des heutigen Wertes sind das?
5. Interpretieren Sie folgenden **R**-Code und geben Sie an, welcher Output auf dem Monitor erscheint:

```
>t=sqrt(180)*(-0.15-0)/(sqrt(1.44))
>ks=qnorm(0.05,0,1)
>if(t<ks){
>print("H0 wird abgelehnt")
>else
>print("H0 kann nicht verworfen werden") }
```

## Aufgabe 2

In 100 ausgewählten Landkreisen in Deutschland wurde der Zusammenhang zwischen der durchschnittlichen Arbeitslosenquote und der durchschnittlichen Kinderzahl je Frau im Jahr 2008 untersucht. Das Merkmal  $X$  stellt "Durchschnittliche Kinderzahl je Frau von... bis... in einem Landkreis im Jahr 2008" dar, und das Merkmal  $Y$  bezeichnet "Durchschnittliche Arbeitslosenquote von... bis... in einem Landkreis im Jahr 2008 in %".

Die relativen Häufigkeiten für die beiden Merkmale sind in nachfolgender Tabelle zusammengefasst:

$(\tilde{x}_{i-1}; \tilde{x}_i] \downarrow \setminus (\tilde{y}_{j-1}; \tilde{y}_j] \rightarrow$	0 - 6	6 - 10	10 - 16	16 - 25
0.9 - 1.3	0.05	0.03	0.01	0.00
1.3 - 1.5	0.45	0.07	0.18	0.05
1.5 - 1.8	0.10	0.05	0.01	0.00

- Bestimmen Sie die Randverteilung des Merkmals  $Y$  und stellen Sie dessen relative Häufigkeiten sowie die approximierende Verteilungsfunktion geeignet graphisch dar. Welche Annahme müssen Sie hierbei treffen?
- Bestimmen Sie den Median der Häufigkeitsverteilung des Merkmals  $Y$  und interpretieren Sie diesen.
- Wieviel Prozent der betrachteten Landkreise wiesen im Jahre 2008 eine Arbeitslosenquote unter 15% auf?
- Berechnen Sie die Werte der zweidimensionalen Verteilungsfunktion  $F_{X,Y}(x, y)$  an den Klassengrenzen. Interpretieren Sie den Wert  $F_{X,Y}(\tilde{x}_2, \tilde{y}_3)$ .
- Gegeben seien  $\bar{y} = 6.625$ ,  $\bar{x} = 1.413$ ,  $s_X^2 = 0.0179$  und  $\sum_{i=1}^3 \sum_{j=1}^4 \frac{\tilde{x}_{i-1} + \tilde{x}_i}{2} \frac{\tilde{y}_{j-1} + \tilde{y}_j}{2} f_{ij} = 9.3265$ . Berechnen Sie den Korrelationskoeffizienten für die Merkmale  $X$  und  $Y$ .
- Die Klassengrenzen sowie die entsprechenden relativen Häufigkeiten der Klassen des Merkmals  $X$  aus der Angabe wurden in **R** bereits angegeben:

```
> x=c(0.9,1.3,1.5,1.8)
> fi=c(0.09, 0.75, 0.16)
```

Geben Sie die Befehle zur Bestimmung von  $\bar{x}$  in **R** an?

## Aufgabe 3

Eine Zufallsvariable  $X$  ist doppelt exponentialverteilt, d.h. die Dichte besitzt folgende Gestalt:

$$f_X(x) = \theta/2 \cdot e^{-\theta|x|} = \begin{cases} (\theta/2)e^{\theta x} & \text{für } x \leq 0, \\ (\theta/2)e^{-\theta x} & \text{für } x > 0. \end{cases}$$

1. Zeigen Sie, dass  $f_X(x)$  tatsächlich eine Dichtefunktion darstellt.
2. Zeigen Sie, dass die Verteilungsfunktion  $F_X(x)$  folgende Gestalt hat:

$$F_X(x) = \begin{cases} 1/2e^{\theta x} & \text{für } x \leq 0, \\ 1 - 1/2e^{-\theta x} & \text{für } x > 0. \end{cases}$$

3. Skizzieren Sie für  $\theta = 1$  die Dichtefunktion  $f_X(x)$  für  $-3 \leq x \leq 3$ .
4. Zeigen Sie, dass die Log-Likelihoodfunktion folgende Gestalt besitzt:

$$\ln L(\theta; x_1, x_2, \dots, x_n) = n \ln(\theta) - n \ln(2) - \theta \sum_{i=1}^n |x_i|.$$

Leiten Sie anschließend den ML-Schätzer für  $\theta$  her, ohne Berechnung der 2. Ableitung.

**Hinweis:** Falls Sie kein Ergebnis erhalten haben, verwenden Sie im Folgenden:

$$\hat{\theta} = \frac{n}{\sum_{i=1}^n |x_i|}.$$

5. Aufgrund einer Stichprobe wissen Sie, dass  $\sum_{i=1}^{10} |x_i| = 12$ . Zeichnen Sie für  $\theta = 10/13, 10/12, 10/11$  die Funktionswerte der Log-Likelihoodfunktion in ein geeignetes Koordinatensystem ein.
6. Erzeugen Sie eine Zahlenfolge  $y$  in  $\mathbf{R}$  der Länge 1000 für  $-3 \leq y \leq 3$ .
7. Schreiben Sie in die Funktion

```
> my.fun=function(x){...}
```

die Dichtefunktion einer doppelten Exponentialverteilung zum Parameter  $\theta = 1$ .

**Hinweis:** Sie können die  $\mathbf{R}$ -Funktion `abs(x)` verwenden, die den Absolutbetrag des Arguments  $x$  zurück gibt.

8. Plotten Sie die Funktion `my.fun` für den Vektor  $y$ .

## Aufgabe 4

Es erfolgt eine Zeitmessung beim 1000-Meter-Lauf bei acht untrainierten Jugendlichen. Nach einem sechsmonatigen Training laufen die Probanden wieder eine 1000-Meter-Strecke. Die erfasste Zeit in Minuten für beide 1000-Meter-Läufe ist in nachfolgender Tabelle präsentiert:

Proband $i$	1	2	3	4	5	6	7	8
Laufzeit vor dem Trainig $x_i$	4.37	2.55	4.88	3.35	3.85	3.12	2.97	4.25
Laufzeit nach dem Trainig $y_i$	3.20	2.50	4.10	3.02	2.86	2.90	2.80	3.50

Die Zufallsvariablen  $V$ : "logarithmierte benötigte Zeit beim 1000-Meter-Lauf vor dem Training" und  $W$ : "logarithmierte benötigte Zeit beim 1000-Meter-Lauf nach dem Training" sind in der Grundgesamtheit mit  $(\mu_V, \sigma_V^2)$  und  $(\mu_W, \sigma_W^2)$  verteilt.

1. Wie ist das Stichprobenmittel  $\bar{W}_n$  für großen Stichprobenumfang  $n$  verteilt? Begründen Sie kurz Ihre Antwort.

Nun seien  $V$  und  $W$  normalverteilt:  $V \sim N(\mu_V, \sigma_V^2)$  und  $W \sim N(\mu_W, \sigma_W^2)$ . Anhand erhobener Stichprobe wurde bereits errechnet, dass  $\bar{v}_8 = 1.2783$ ,  $\bar{w}_8 = 1.1242$  und  $s_W^2 = 0.0231$ .

2. Berechnen Sie die Stichprobenvarianz von  $V$ .

**Hinweis:** Beachten Sie dabei, dass die Zufallsvariablen  $V$  und  $W$  logarithmierte Zeiten darstellen.

3. (a) Testen Sie die Vermutung, dass das sechsmonatige Training einen signifikanten Einfluss auf die durchschnittliche Leistung der Probanden hat, mit einer Irrtumswahrscheinlichkeit von 5%.  
Zusätzlich wurden die gepoolte Stichprobenvarianz  $\bar{s}^2 = 0.0361$  sowie die Stichprobenvarianz der Differenzen  $s_D^2 = 0.0391$  berechnet.  
(b) Bei welcher **tabellierten** Irrtumswahrscheinlichkeit würde sich die Testentscheidung umkehren? (Keine Berechnung erforderlich)
4. (a) Wie groß muss der Stichprobenumfang gewählt werden, damit das Stichprobenmittel  $\bar{W}_n$  mit einer Vertrauenswürdigkeit von 95% maximal um 0.05 von dem wahren Mittelwert  $\mu_W$  abweicht. Die Varianz von  $W$  sei bekannt und betrage  $\sigma_W^2 = 0.0231$ .  
(b) Interpretieren Sie das realisierte Konfidenzintervall  $[1.0742; 1.1742]$  für den Mittelwert  $\mu_W$ .
5. Es soll eine Funktion in **R** zur Bestimmung des Konfidenzintervalls für die Varianz bei unbekanntem Mittelwert erstellt werden.  
(a) Geben Sie den Befehl zur Erstellung einer Funktion `KI.Var` an, der das Command-Window aufruft.  
(b) Nachdem sich das Command-Window geöffnet hat, sehen Sie nachfolgendes Schema. Vervollständigen Sie dieses:

```
function(S^2, n, niveau)
{
alpha=1-niveau
...
return(KI)
}
```

# Lösung zu Aufgabe 1

1. Gegeben ist  $P(R) = 0.6$ ,  $P(\bar{F}) = 0.3$ ,  $P(R|F) = 0.8$

	$R$	$\bar{R}$	
$F$	0.56	0.14	0.7
$\bar{F}$	0.04	0.26	0.3
	0.6	0.4	1

Hilfsrechnung:  $P(R \cap F) = P(R|F) \cdot P(F) = 0.8 \cdot 0.7 = 0.56$

2. Berechnen Sie folgende W'keiten:

(a)  $P(R \cap \bar{F}) = 0.04$  (aus Tabelle ablesen)

(b)  $P(\bar{R}|F) = \frac{P(\bar{R} \cap F)}{P(F)} = \frac{0.14}{0.7} = 0.2$

(c)  $P(F|\bar{R}) = \frac{P(\bar{R} \cap F)}{P(\bar{R})} = \frac{0.14}{0.4} = 0.35$

3.  $P(R \cap F) = 0.56 \neq 0.7 \cdot 0.6 = P(R) \cdot P(F)$  A: Nein, Sie sind stochastisch abhängig.

4. (a) Einseitiger Hypothesentest für den Mittelwert mit bekannter Varianz :

$$H_0 : \mu \geq 0 \text{ gegen } H_1 : \mu < 0$$

Kritischer Bereich:

$$\sqrt{n} \frac{\bar{X}_n - \mu_0}{\sqrt{\sigma^2}} < \lambda(0.05) = -\lambda(1 - 0.05)$$

Aufstellen der Teststatistik:

$$t = \sqrt{180} \cdot (-0.15 - 0) / \sqrt{1.44} = -1.6770$$

Berechnung der kritischen Schranke:

$$KS = \lambda(0.05) = -1.645$$

Testentscheidung:

Da  $t < KS$  wird  $H_0$  auf dem 5%-Signifikanzniveau abgelehnt.

- (b) Wert der PF heute:  $S_0 = 50 \cdot 10 = 500$

Erwarteter Wert in einem Jahr:  $S_1 = S_0 \cdot e^{-0.14} = 434.6791$ . Prozentualer Wert:

$$S_1/S_0 = 434.6791/500 = 0.8693582 \approx 86.94\%$$

5. 1. Zeile: Die Teststatistik aus 5.a wird ausgerechnet.  
 2. Zeile: Die kritische Schranke aus 5.a wird berechnet, also das 95%- Quantil einer Standardnormalverteilung.  
 3.-6. Zeile: Es wird mit Hilfe einer if Schleife eine Testentscheidung durchgeführt: Falls die Statistik kleiner als die kritische Schranke ist, erscheint die Ausgabe: H0 wird abgelehnt, falls nicht, dann: H0 wird nicht abgelehnt. Es erscheint als Output: H0 wird abgelehnt.

## Lösung zu Aufgabe 2

1. Tabelle:

$i$	von ... bis unter ... %	$\Delta y_i$	$f_i$	$F_i$	$f_i^*$	$y_i$
1	0 - 6	6	0.60	0.60	0.1000	3.00
2	6 - 10	4	0.15	0.75	0.0375	8.00
3	10 - 16	6	0.20	0.95	0.0333	13.00
4	16 - 25	9	0.05	1	0.0056	20.50

Zeichnung: Histogramm für relative Häufigkeiten . Polygonzug für die Verteilungsfunktion. Annahme: Gleichverteilung in den Klassen.

2. (a) Bestimmung des Medians für klassierte Daten:

$$y_{(0.5)} = \tilde{y}_0 + \frac{0.5 - F(\tilde{y}_0)}{f_1} \cdot \Delta y_1 = 0 + \frac{0.5 - 0.00}{0.60} \cdot 6 = 5.$$

(b) Interpretation: Die Arbeitslosenquote von 5 % wird in mindestens 50 % aller betrachteten Landkreisen nicht überschritten .

3. Approximierende Verteilungsfunktion:

$$F^*(15) = (0.75 + (15 - 10) \cdot 0.0333) = 0.9165,$$

⇒ Bei 91.65 % aller betrachteten Landkreise wurden maximal eine 15% Arbeitslosenquote ermittelt.

4. Die zweidimensionale Verteilungsfunktion  $F_{X,Y}(x, y) = f(X \leq x, Y \leq y)$  lautet:

$X \downarrow \backslash Y \rightarrow$	0 - 6	6 - 10	10 - 16	16 - 25
0.9 - 1.3	0.05	0.08	0.09	0.09
1.3 - 1.5	0.50	0.60	0.79	0.84
1.5 - 1.8	0.60	0.75	0.95	1.00

Der Wert  $F_{X,Y}(\tilde{x}_2 = 1.5, \tilde{y}_3 = 16) = 0.79$  bedeutet, dass 79% der betrachteten Landkreise eine Arbeitslosenquote höchstens 16 % und gleichzeitig eine durchschnittliche Kinderzahl je Frau maximal 1.5 aufweisen.

5. Korrelationskoeffizient für Merkmale  $X$  und  $Y$ :  $r_{XY} = \frac{s_{XY}}{s_X s_Y}$

- Berechnung der Varianz von  $Y$  :

$$s_Y^2 = \sum_{i=1}^k y_i^2 f_i - \bar{y}^2 = 9 \cdot 0.6 + 64 \cdot 0.15 + 169 \cdot 0.2 + 420.25 \cdot 0.05 - 6.625^2 = 25.9219$$

- Kovarianz von  $X$  und  $Y$  :

$$s_{XY} = s_{YX} = \overline{x \cdot y} - \bar{x} \cdot \bar{y} = 9.3265 - 1.4130 \cdot 6.625 = -0.0346$$

- Korrelationskoeffizient :

$$r_{XY} = \frac{-0.0346}{\sqrt{0.0179 \cdot 25.9219}} = -0.0508$$

Es besteht ein sehr geringer negativer Zusammenhang zw. den Merkmalen  $X$  und  $Y$ .

6. Lösung zu **R**-Aufgaben:

```
> xl=x[1:(length(x)-1)] # Untergrenzen der Klassen
> xu=x[2:(length(x))]   # Obergrenzen der Klassen
> xm=(xu+xl)/2          # Klassenmitten
> sum(xm*fi)             # Mittelwert von X
```

## Lösung zu Aufgabe 3

### 1. Prüfe

(a)  $f(x) \geq 0$  für alle  $x \in \mathbb{R}$ : Erfüllt, da  $\theta > 0$  und die Exponentialfunktion immer größer als 0.

(b)

$$\begin{aligned}\int_{-\infty}^{\infty} f(x) dx &= \int_{-\infty}^{\infty} \frac{\theta}{2} e^{-\theta|x|} dx \\ &= 1/2 \left( \int_{-\infty}^0 \theta e^{\theta x} dx + \int_0^{\infty} \theta e^{-\theta x} dx \right) \\ &= 1/2 \left( e^{\theta x} \Big|_{-\infty}^0 + (-e^{-\theta x}) \Big|_0^{\infty} \right) \\ &= 1/2(1 - 0 + (0 - (-1))) = 1\end{aligned}$$

### 2. Lösung z.B. durch Integration über $f_X$ :

(a) für  $x \leq 0$

$$P(X \leq x) = F(x) = \int_{-\infty}^x \frac{\theta}{2} e^{\theta t} dt = 1/2 e^{\theta t} \Big|_{-\infty}^x = 1/2 e^{\theta x}$$

(b) für  $x > 0$

$$\begin{aligned}P(X \leq x) = F(x) &= F(0) + \int_0^x \frac{\theta}{2} e^{-\theta t} dt \\ &= 1/2 + 1/2(1 - e^{-\theta t}) \Big|_0^x = 1 - 1/2 e^{-\theta x}\end{aligned}$$

### 3. Graph der Dichtefunktion $f(x)$ für $-3 \leq x \leq 3$

### 4. Aufstellen der Log-Likelihoodfunktion

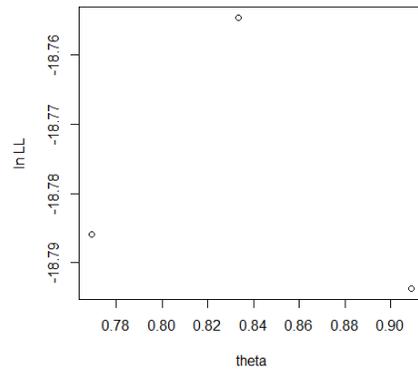
$$\begin{aligned}L(\theta; x_i) &= \prod_{i=1}^n \frac{\theta}{2} e^{-\theta|x_i|} \\ &= \left(\frac{\theta}{2}\right)^n e^{-\sum_{i=1}^n \theta|x_i|} \\ \Rightarrow \ln L(\theta; x_i) &= n(\ln(\theta) - \ln(2)) - \theta \sum_{i=1}^n |x_i|\end{aligned}$$

Bestimmung des Maximums mit Hilfe der ersten Ableitung:

$$\begin{aligned}\frac{\partial \ln L(\theta; x_i)}{\partial \theta} &= n/\theta - \sum_{i=1}^n |x_i| \stackrel{!}{=} 0 \\ \Leftrightarrow \theta &= \frac{n}{(\sum_{i=1}^n |x_i|)}\end{aligned}$$

5. Graph von  $LL$ : Wertetabelle:

$\theta$	10/13	10/12	10/11
$LL(\theta)$	-18.790	-18.755	-18.793



6. `> y=seq(-3,3,length=1000)`

7. `> my.fun=function(x){1/2*exp(-abs(x))}`

8. `> plot(y, my.fun(y))`

## Lösung zu Aufgabe 4

1. Approximative Verteilung des Stichprobenmittels:

$$\bar{W}_n \sim N\left(\mu_W; \frac{\sigma_W^2}{n}\right)$$

Begründung: zentraler Grenzwertsatz.

2. Berechnung der Stichprobenvarianz von  $W$ :

- (a) Logarithmieren der angegebenen Zeiten:

Proband $i$	1	2	3	4	5	6	7	8
Laufzeit $x_i$	4.37	2.55	4.88	3.35	3.85	3.12	2.97	4.25
Log. Zeit $v_i$	1.4748	0.9361	1.5851	1.209	1.3481	1.1378	1.0886	1.4469

(b)  $s_V^2 = \frac{1}{8-1} ((1.4748 - 1.2783)^2 + (0.9361 - 1.2783)^2 + \dots + (1.4469 - 1.2783)^2) = 0.0491$

3. (a) Mittelwertdifferenztest bei verbundenen Stichproben :

$$H_0 : \mu_V - \mu_W \leq 0 \text{ gegen } H_A : \mu_V - \mu_W > 0$$

Kritischer Bereich:

$$\sqrt{n} \frac{\bar{V}_n - \bar{W}_n - \delta_0}{S_D} > t_{1-\alpha; n-1}$$

Teststatistik (aus der Angabe  $S_D^2 = 0.0391$ ):

$$t = \sqrt{8} \frac{1.2783 - 1.1242 - 0}{\sqrt{0.0391}} = 2.2042$$

Kritische Schranke  $t_{1-\alpha; n-1} = t_{0.95; 7} = 1.895$

Testentscheidung: Da  $t = 2.2042 > 1.895 = t_{0.95; 7}$ , wir  $H_0$  abgelehnt.

- (b) Die Testentscheidung kehrt sich erst bei  $\alpha = 0.03$  um.

4. (a) KI für den Mittelwert bei bekannter Varianz, hierbei muss  $\lambda_{1-\alpha/2} \cdot \frac{\sigma_W}{\sqrt{n}} \leq 0.05$  sein, d.h.,  $\frac{\lambda_{0.975} \cdot \sqrt{0.0231}}{\sqrt{n}} \leq 0.05$ , wobei  $\lambda_{0.975} = 1,96, \Rightarrow n \geq \left(\frac{1,96}{0,05}\right)^2 \cdot 0.0231 = 35.5, \Rightarrow n \geq 36$ .

- (b) Mit einer Vertrauenswürdigkeit von 95% liegt der wahre Mittelwert im realisierten KI. **ODER:** Wenn man viele Stichproben zieht und die KI für den Mittelwert berechnet, dann fällt in 95 von 100 gezogenen Stichproben der wahre Parameter in das realisierte KI.

5. a) `> KI.Var=fix(KI.Var)`

```
b) function(S^2, n, niveau)
{ alpha=1-niveau
KI_l=(n-1)S^2/qchisq(1-alpha/2, n-1)
KI_u=(n-1)S^2/qchisq(alpha/2, n-1)
KI=c(KI_l, KI_u)
return(KI)}
```