

Klausur Statistik (7.5 ECTS)

Name		Prüfer	Prof. Dr. I. Klein
Vorname		Arbeitszeit	Freitag, 19.02.2016 14:00 - 16:00 Uhr
Matrikelnummer			
Studienrichtung		Sitzplatznummer	
Semesterzahl		Raum	
Email (optional)			

Hinweis: Aufgabenblätter nicht auseinandertrennen!

Ergebnis:

Statistik	
Aufgabe	Punkte
1	
2	
3	
4	
Summe	
Note:	

Unterschrift des Kandidaten: _____

Unterschrift des Prüfers: _____

Hilfsmittel:

Es gelten folgende Regelungen zu den erlaubten Hilfsmitteln:

- Nicht programmierbarer Taschenrechner
- Die vom Lehrstuhl seit dem WS 2014/15 offiziell herausgegebene Formelsammlung (DIN A5, gebunden, orangener Umschlag). Es sind prinzipiell keine weiteren Eintragungen oder Markierungen darin erlaubt. Ausgenommen sind farbliche Hinterlegungen von Textpassagen und/oder Formeln. Außerdem ist das Erratum zur 1. Auflage der Formelsammlung erlaubt.
- R Reference Card von Jonathan Baron, es sind keine weiteren Eintragungen oder Markierungen darin erlaubt.

Bewertung:

Für jede Aufgabe werden maximal zehn Punkte vergeben. Bewertet werden grundsätzlich nur Lösungen, die im Lösungsteil stehen und für die Folgendes beachtet wird:


- Der Lösungsweg muss aus einer Darstellung der einzelnen Rechenschritte ersichtlich sein.
- Antworten sind stets zu begründen, es sei denn es wird ausdrücklich keine Begründung verlangt.
- Unleserliche Aufgabenteile werden mit 0 Punkten bewertet.

Viel Erfolg!


Schmierpapier zu Aufgabe 1



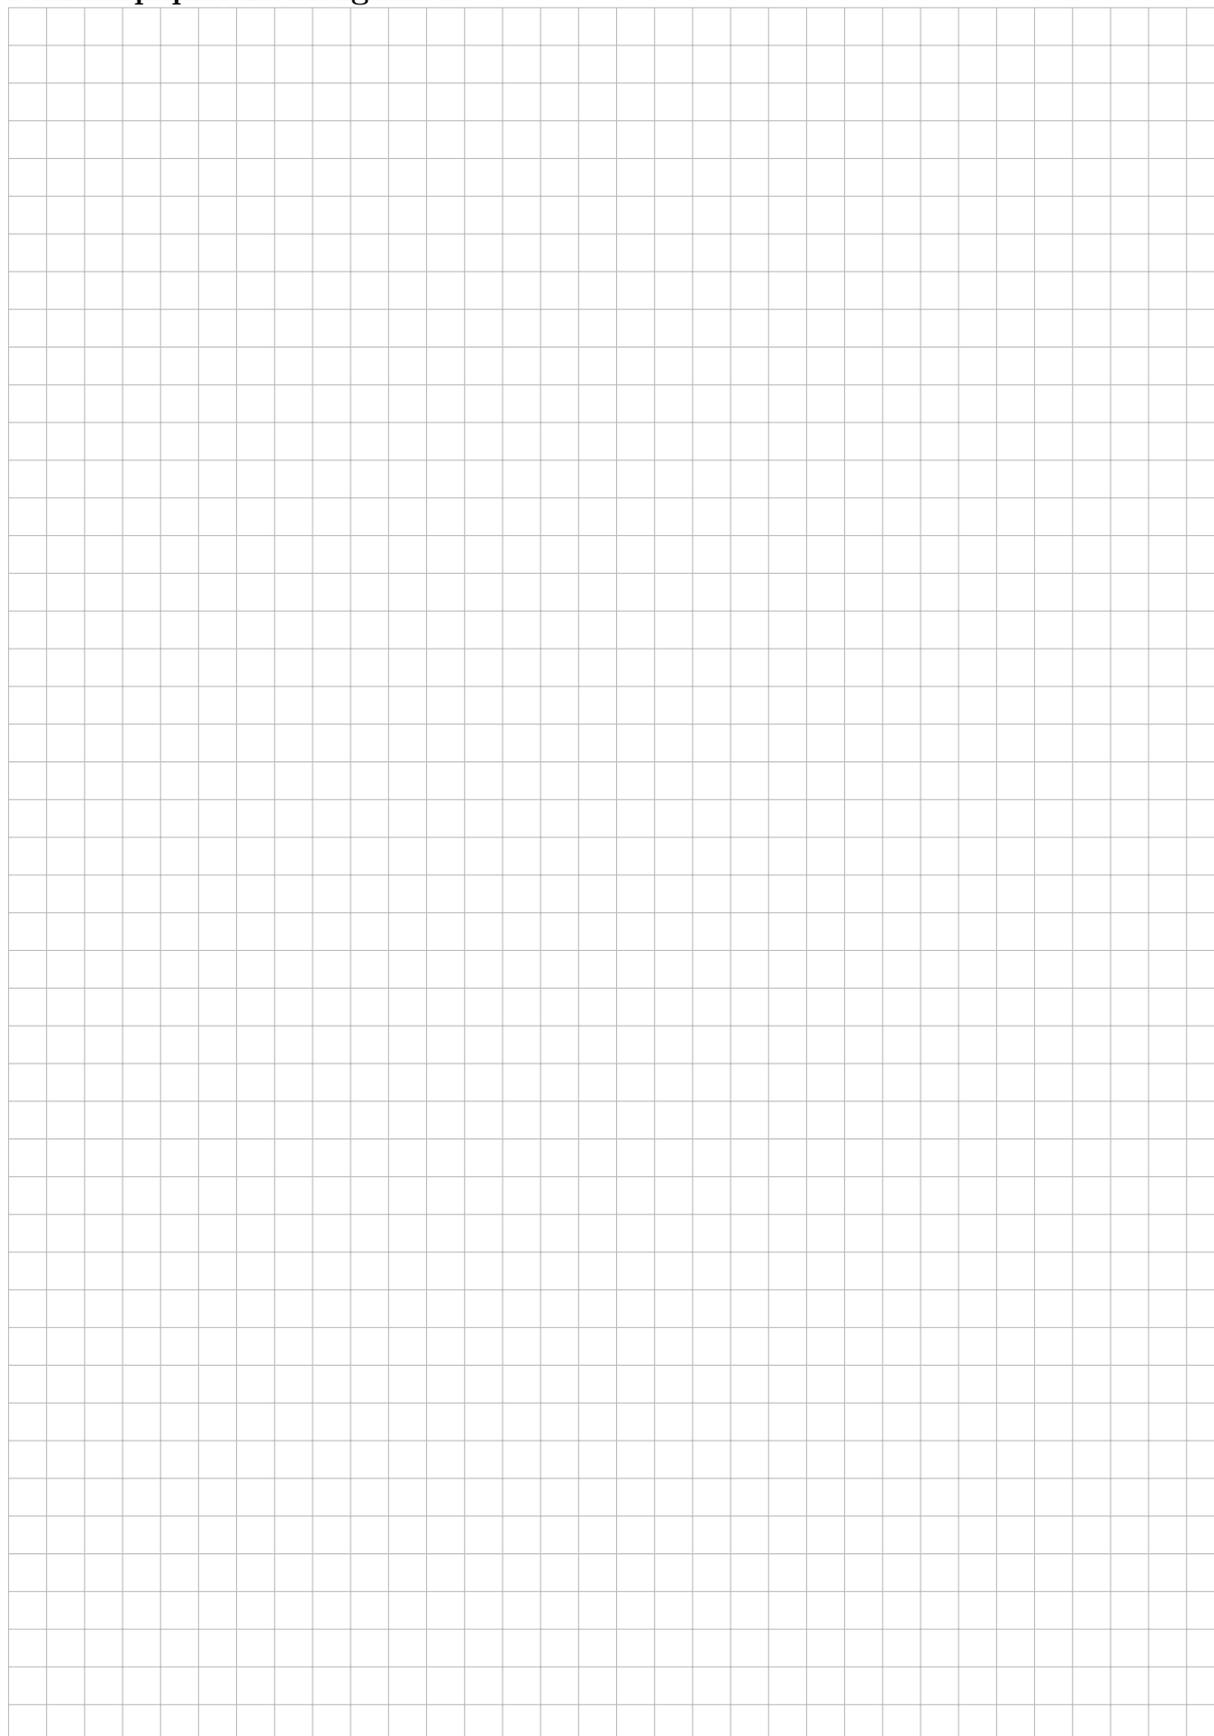
Schmierpapier zu Aufgabe 2



Schmierpapier zu Aufgabe 3



Schmierpapier zu Aufgabe 4



Lösung Klausur WS1516 (7.5 ECTS)

Lösung 1

- 1) Nominalskala 0.5 P
- 2) $81174 \cdot 1.02 \cdot 0.98 = 81141.5304$ 0.5 P
- 3) $\frac{36000 \cdot 81174 + 32200 \cdot 66352}{81174 + 66352} = 34290.8938$ 1.0 P
- 4) $\frac{350 + 400}{\frac{350}{100} + \frac{400}{80}} = 88.2353$ 1.0 P
- 5) $\lambda = 4.5$ 0.5 P
- 6) $P(Y_1 = 2) = 0.2240$ 0.5 P
- 7) $P(Y_1 > 2)P(Y_2 \leq 3) = (1 - 0.4232) \cdot 0.6472 = 0.3733$ 1.5 P
- 8) $F_{exp}(10; \frac{3}{90}) = 1 - exp(-\frac{3}{90} \cdot 10) = 0.2835$ 1.5 P
- 9) $\sum_{i=1}^n (x_i - \bar{x}_n)^2 = \sum_{i=1}^n x_i^2 - \underbrace{\sum_{i=1}^n 2x_i \bar{x}_n}_{=2n\bar{x}_n} + \underbrace{\sum_{i=1}^n \bar{x}_n^2}_{=n\bar{x}_n^2} = \sum_{i=1}^n x_i^2 - 2n\bar{x}_n^2 + n\bar{x}_n^2 = \sum_{i=1}^n x_i^2 - n\bar{x}_n^2$ 1.0 P
- 10) $t_n = \frac{\sum_{i=1}^n (x_i - \bar{x}_n)^2}{\sigma_0^2} = \frac{309570 - 23 \cdot 116^2}{64} = 1.2813$ 1.0 P
- 11) Lehne H_0 nicht ab, da $PG < KS$ (PG nicht im KB). 1.0 P

Lösung 2

1. Der Erwartungswert des Schätzers entspricht dem wahren Parameterwert. 0.5 P

$$2. \widehat{Var}(\bar{H}) = \frac{1}{n-1} \sum_{i=1}^n (H_i - \bar{H}_n)^2 = \frac{n}{n-1} \left(\frac{1}{n} \sum_{i=1}^n H_i^2 - \bar{H}_n^2 \right) = \frac{100}{99} \left(\frac{190.43}{100} - \left(\frac{102.30}{100} \right)^2 \right) = 0.8664 \quad 1.5 \text{ P}$$

3. nicht eindeutig; asymptotisch erwartungstreu; MSE-konsistent; asymptotisch normalverteilt 0.5 P

4. a) $P(H = 3) = 0$ 0.5 P


b) $P(H > 1) = 1 - P(H \leq 1) = 1 - (1 - e^{-1}) = e^{-1} \approx 0.3679$ 1 P

c) $P(H \leq 4 | H > 3) = F_{Exp(1)}(4) - F_{Exp(1)}(3) = 1 - \exp\{-1\} = 0.6321$ 1 P

oder: $P(H \leq 4 | H > 3) = \frac{P(3 < H \leq 4)}{P(H > 3)} = \frac{F_{Exp(1)}(4) - F_{Exp(1)}(3)}{1 - F_{Exp(1)}(3)} = 0.6321$

5. $\lambda = \frac{1}{5} = 0.2$ 0.5 P

6. Der Median entspricht dem 50%-Quantil der Verteilung: 0.5 P



7. a) $\left[\frac{\chi_{\alpha; 2n}^2}{2n\bar{Z}} ; \infty \right) = \left[\frac{\chi_{0.05; 40}^2}{2 \cdot 51.75} ; \infty \right) = \left[\frac{26.51}{103.5} ; \infty \right) = [0.2561 ; \infty)$ 1.5 P

b) In 95 von 100 Fällen liegt der wahre Parameter im real. Konfidenzintervall.

oder

Mit einer Vertrauenswürdigkeit von 95% liegt der Parameter im realisierten Konfidenzintervall 0.5 P

8. a) $t_{20} = 2 \cdot \frac{1}{5} \cdot 51.75 = 20.7$ 0.5 P

b) $p = P(T_N \leq t_{20}) = P(T_N \leq 20.7) = 0.005 = 0.5\%$ 0.5 P

($p = P(T_N \leq t_{20}) = P(T_N \leq 22.16) = 1\%$)

c) $p = 0.005(0.1) < 0.05 = \alpha$

\implies Nullhypothese kann auf dem 5%-Niveau abgelehnt werden,

oder

$\lambda_0 = 0.2$ liegt nicht im realisierten Konfidenzintervall, daher kann die Nullhypothese abgelehnt werden,

oder

$t_{20} = 20.7 < 26.51 = \chi_{0.05;40}^2 = \chi_{\alpha;2n}^2$, daher kann die Nullhypothese abgelehnt werden.

1 P

Lösung 3

1. a) $[\mu_w - 2 \cdot \sigma_k; \mu_w + 2 \cdot \sigma_k]$
 $= [6.37 - 2 \cdot \sqrt{0.04}; 6.37 + 2 \cdot \sqrt{0.04}] = [5.97; 6.77]$ 1.0 P
- b) $\Phi(1.53) - \Phi(-1.53) = 2 \cdot 0.9370 - 1 = 0.8740$ 1.0 P
- c) $P(W \geq 6.50) = 1 - P\left(\frac{W - \mu_w}{\sigma_w} \leq \frac{6.50 - \mu_w}{\sigma_w}\right) =$
 $1 - P\left(\frac{W - \mu_w}{\sigma_w} \leq \frac{6.50 - 6.37}{\sqrt{0.04}}\right) = 1 - \Phi(0.65) = 1 - 0.7422 = 0.2578$ 1.5 P
- d) $\bar{w}_n = 6.3480$ 0.5 P
- e) Spannweite = $6.51 - 6.18 = 0.33$ 0.5 P
2. a) Likelihoodfunktion:
 $L = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(x_i - \mu)^2}{2\sigma^2}\right\}$
 Log-Likelihoodfunktion:
 $\ln(L) = n \ln(1) - n \ln(\sigma\sqrt{2\pi}) - \left(\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}\right)$
 $= -n \ln(\sigma\sqrt{2\pi}) - \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}$ 1.5 P
- b) 1. Ableiten: $\frac{\partial \ln L}{\partial \mu} : \frac{\sum_{i=1}^n (x_i - \mu)}{\sigma^2}$ 0.5 P
 2. Gleich 0 setzen: $\hat{\mu}_{ML} = \frac{1}{n} \sum_{i=1}^n x_i$ 0.5 P
- c) $\frac{179}{20} = 8.95[\text{sec}]$ 0.5 P
- d) Die zweite Ableitung der (logarithmierten) Likelihoodfunktion muss an der Stelle des ML-Schätzers $\hat{\mu}_{ML}$ negativ sein. 0.5 P +0.5 P
3. a) $f_Z(z) = \frac{1}{43} = 0.0233$ 0.5 P
 b) Geometrische Verteilung 0.5 P
 c) $E[Z] = 42$ 0.5 P

Lösung 4

- | | | F | \bar{F} | Σ | | |
|----|----|----------|-----------|----------|-----|-----|
| 1. | a) | W_1 | 0.006 | 0.194 | 0.2 | 2 P |
| | | W_2 | 0.0056 | 0.7944 | 0.8 | |
| | | Σ | 0.0116 | 0.9884 | 1 | |
- b) 98.84% ✓ 0.5 P
- c) 100% ✓ 0.5 P
- d) $\frac{0.0056}{0.0116} \checkmark = 0.4828 \checkmark$ 1 P
2. Sie stimmen überein. ✓ 0.5 P
3. $\sum_{i=1}^n X_i \sim \text{Bin}(n, p) \checkmark \checkmark$ 1 P
4. $n \geq \left(\lambda_{1-\alpha/2} \frac{1}{2\varepsilon}\right)^2 = \left(1.6448 \frac{1}{2 \cdot 0.02}\right)^2 \checkmark = 1690.854 \checkmark$ d.h. $n \geq 1691 \checkmark$ 1.5 P
5. a) 0.5 ✓ 0.5 P
- b)
- $$f(p) = p(1-p) \Rightarrow f'(p) = 1 - 2p \checkmark$$
- $$p \in]0, 0.1] \Rightarrow f'(p) \in [0.8, 1[\text{ insbesondere: } f'(p) > 0 \checkmark$$
- $$p \in]0, 0.1] \Rightarrow p(1-p) \leq 0.1(1-0.1) = 0.09 \checkmark$$
- 1.5 P
- c) $n \geq \frac{9}{\alpha\varepsilon^2} \checkmark = \frac{0.09}{0.1 \cdot 0.02^2} = 2250 \checkmark$ 1 P

Klausur Statistik (10 ECTS)

Name		Prüfer	Prof. Dr. I. Klein
Vorname		Arbeitszeit	Freitag, 19.02.2016 14:00 - 16:00 Uhr
Matrikelnummer			
Studienrichtung		Sitzplatznummer	
Semesterzahl		Raum	
Email (optional)			

Hinweis: Aufgabenblätter nicht auseinandertrennen!

Ergebnis:

Statistik	
Aufgabe	Punkte
1	
2	
3	
4	
Summe	
Note:	

Unterschrift des Kandidaten: _____

Unterschrift des Prüfers: _____

Hilfsmittel:

Es gelten folgende Regelungen zu den erlaubten Hilfsmitteln:

- Nicht programmierbarer Taschenrechner
- Die vom Lehrstuhl seit dem WS 2014/15 offiziell herausgegebene Formelsammlung (DIN A5, gebunden, orangener Umschlag). Es sind prinzipiell keine weiteren Eintragungen oder Markierungen darin erlaubt. Ausgenommen sind farbliche Hinterlegungen von Textpassagen und/oder Formeln. Außerdem ist das Erratum zur 1. Auflage der Formelsammlung erlaubt.
- R Reference Card von Jonathan Baron, es sind keine weiteren Eintragungen oder Markierungen darin erlaubt.


Bewertung:

Für jede Aufgabe werden maximal zehn Punkte vergeben. Bewertet werden grundsätzlich nur Lösungen, die im Lösungsteil stehen und für die Folgendes beachtet wird:


- Der Lösungsweg muss aus einer Darstellung der einzelnen Rechenschritte ersichtlich sein.
- Antworten sind stets zu begründen, es sei denn es wird ausdrücklich keine Begründung verlangt.
- Unleserliche Aufgabenteile werden mit 0 Punkten bewertet.

Viel Erfolg!


Schmierpapier zu Aufgabe 1



Schmierpapier zu Aufgabe 2



Schmierpapier zu Aufgabe 3




Aufgabe 4

In Ihrem Workspace liegt ein bereits erstellter Dataframe `MovieLens` mit Daten aus dem *MovieLens 100 K Datensatz*² vor, in welchem die Nutzerbewertungen von Filmen aufgelistet sind. Weiterhin sind in ihm folgende Merkmale enthalten:

Merkmalsname	Beschreibung	Spaltenname
<i>User ID:</i>	Identifikationsnummer des Users	<code>user_id</code>
<i>Filmtitel:</i>	Titel des bewerteten Films	<code>movie_title</code>
<i>Genre:</i>	Genre des bewerteten Films	<code>genre</code>
<i>Rating:</i>	Bewertung des Films (1 bis 5 Sterne)	<code>rating</code>
<i>Alter:</i>	Alter des Users	<code>age</code>
<i>Geschlecht:</i>	Geschlecht des Users	<code>gender</code>
<i>Beruf:</i>	Beruf(sgruppe) des Users	<code>occupation</code>


Die folgende Grafik enthält ein Tortendiagramm, welches erstellt wurde durch den Befehl:

```
> pie(table(MovieLens$occupation))
```



²https://github.com/JustinChu/STAT545A_MovieStats.git

Schmierpapier zu Aufgabe 4



Lösung Klausur WS1516 (10 ECTS)

Lösung 1

- 1) Nominalskala 0.5 P
- 2) $81174 \cdot 1.02 \cdot 0.98 = 81141.5304$ 0.5 P
- 3) $\frac{36000 \cdot 81174 + 32200 \cdot 66352}{81174 + 66352} = 34290.8938$ 1.0 P
- 4) $\frac{350 + 400}{\frac{350}{100} + \frac{400}{80}} = 88.2353$ 1.0 P
- 5) $\lambda = 4.5$ 0.5 P
- 6) $P(Y_1 = 2) = 0.2240$ 0.5 P
- 7) $P(Y_1 > 2)P(Y_2 \leq 3) = (1 - 0.4232) \cdot 0.6472 = 0.3733$ 1.5 P
- 8) $F_{exp}(10; \frac{3}{90}) = 1 - exp(-\frac{3}{90} \cdot 10) = 0.2835$ 1.5 P
- 9) $\sum_{i=1}^n (x_i - \bar{x}_n)^2 = \sum_{i=1}^n x_i^2 - \underbrace{\sum_{i=1}^n 2x_i \bar{x}_n}_{=2n\bar{x}_n} + \underbrace{\sum_{i=1}^n \bar{x}_n^2}_{=n\bar{x}_n^2} = \sum_{i=1}^n x_i^2 - 2n\bar{x}_n^2 + n\bar{x}_n^2 = \sum_{i=1}^n x_i^2 - n\bar{x}_n^2$ 1.0 P
- 10) $t_n = \frac{\sum_{i=1}^n (x_i - \bar{x}_n)^2}{\sigma_0^2} = \frac{309570 - 23 \cdot 116^2}{64} = 1.2813$ 1.0 P
- 11) Lehne H_0 nicht ab, da $PG < KS$ (PG nicht im KB). 1.0 P

Lösung 2

1. Der Erwartungswert des Schätzers entspricht dem wahren Parameterwert. 0.5 P

$$2. \widehat{Var}(\bar{H}) = \frac{1}{n-1} \sum_{i=1}^n (H_i - \bar{H}_n)^2 = \frac{n}{n-1} \left(\frac{1}{n} \sum_{i=1}^n H_i^2 - \bar{H}_n^2 \right) = \frac{100}{99} \left(\frac{190.43}{100} - \left(\frac{102.30}{100} \right)^2 \right) = 0.8664 \quad 1.5 \text{ P}$$

3. nicht eindeutig; asymptotisch erwartungstreu; MSE-konsistent; asymptotisch normalverteilt 0.5 P

4. a) $P(H = 3) = 0$ 0.5 P


b) $P(H > 1) = 1 - P(H \leq 1) = 1 - (1 - e^{-1}) = e^{-1} \approx 0.3679$ 1 P

c) $P(H \leq 4 | H > 3) = F_{Exp(1)}(4) - F_{Exp(1)}(3) = 1 - \exp\{-1\} = 0.6321$ 1 P

$$\text{oder: } P(H \leq 4 | H > 3) = \frac{P(3 < H \leq 4)}{P(H > 3)} = \frac{F_{Exp(1)}(4) - F_{Exp(1)}(3)}{1 - F_{Exp(1)}(3)} = 0.6321$$

5. $\lambda = \frac{1}{5} = 0.2$ 0.5 P

6. Der Median entspricht dem 50%-Quantil der Verteilung: 0.5 P



7. a) $\left[\frac{\chi_{\alpha; 2n}^2}{2n\bar{Z}} ; \infty \right) = \left[\frac{\chi_{0.05; 40}^2}{2 \cdot 51.75} ; \infty \right) = \left[\frac{26.51}{103.5} ; \infty \right) = [0.2561 ; \infty)$ 1.5 P

b) In 95 von 100 Fällen liegt der wahre Parameter im real. Konfidenzintervall.

oder

Mit einer Vertrauenswürdigkeit von 95% liegt der Parameter im realisierten Konfidenzintervall 0.5 P

8. a) $t_{20} = 2 \cdot \frac{1}{5} \cdot 51.75 = 20.7$ 0.5 P

b) $p = P(T_N \leq t_{20}) = P(T_N \leq 20.7) = 0.005 = 0.5\%$ 0.5 P

$$(p = P(T_N \leq t_{20}) = P(T_N \leq 22.16) = 1\%$$

c) $p = 0.005(0.1) < 0.05 = \alpha$

\implies Nullhypothese kann auf dem 5%-Niveau abgelehnt werden,

oder

$\lambda_0 = 0.2$ liegt nicht im realisierten Konfidenzintervall, daher kann die Nullhypothese abgelehnt werden,

oder

$t_{20} = 20.7 < 26.51 = \chi_{0.05;40}^2 = \chi_{\alpha;2n}^2$, daher kann die Nullhypothese abgelehnt werden.

1 P

Lösung 3

1. a) $[\mu_w - 2 \cdot \sigma_k; \mu_w + 2 \cdot \sigma_k]$
 $= [6.37 - 2 \cdot \sqrt{0.04}; 6.37 + 2 \cdot \sqrt{0.04}] = [5.97; 6.77]$ 1.0 P
- b) $\Phi(1.53) - \Phi(-1.53) = 2 \cdot 0.9370 - 1 = 0.8740$ 1.0 P
- c) $P(W \geq 6.50) = 1 - P\left(\frac{W - \mu_w}{\sigma_w} \leq \frac{6.50 - \mu_w}{\sigma_w}\right) =$
 $1 - P\left(\frac{W - \mu_w}{\sigma_w} \leq \frac{6.50 - 6.37}{\sqrt{0.04}}\right) = 1 - \Phi(0.65) = 1 - 0.7422 = 0.2578$ 1.5 P
- d) $\bar{w}_n = 6.3480$ 0.5 P
- e) Spannweite = $6.51 - 6.18 = 0.33$ 0.5 P
2. a) Likelihoodfunktion:
 $L = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(x_i - \mu)^2}{2\sigma^2}\right\}$
 Log-Likelihoodfunktion:
 $\ln(L) = n \ln(1) - n \ln(\sigma\sqrt{2\pi}) - \left(\sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}\right)$
 $= -n \ln(\sigma\sqrt{2\pi}) - \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}$ 1.5 P
- b) 1. Ableiten: $\frac{\partial \ln L}{\partial \mu} : \frac{\sum_{i=1}^n (x_i - \mu)}{\sigma^2}$ 0.5 P
 2. Gleich 0 setzen: $\hat{\mu}_{ML} = \frac{1}{n} \sum_{i=1}^n x_i$ 0.5 P
- c) $\frac{179}{20} = 8.95[\text{sec}]$ 0.5 P
- d) Die zweite Ableitung der (logarithmierten) Likelihoodfunktion muss an der Stelle des ML-Schätzers $\hat{\mu}_{ML}$ negativ sein. 0.5 P +0.5 P
3. a) $f_Z(z) = \frac{1}{43} = 0.0233$ 0.5 P
 b) Geometrische Verteilung 0.5 P
 c) $E[Z] = 42$ 0.5 P

Lösung 4

1. Student mit Häufigkeit kleiner als 33% 0.5 P + 0.5 P
2. Relative Häufigkeiten des Merkmals `occupation`, Gini Entropie (`ge` und `ge2`) 0.5 P + 0.5 P
3. Ja – identisch, da lediglich alternative Berechnung 0.5 P + 0.5 P
4. `mean(MovieLense$age)`, `which.max(table(MovieLense$gender))` und `quantile(MovieLense$rating,0.5,type = 1)` 0.5 P + 0.5 P + 0.5 P
5. `MovieLense[MovieLense$genre == "Action","occupation"]` 1 P (-0.5 P pro Fehler)
6. `MovieLense[MovieLense$age > 17 & MovieLense$age < 31,]` 1 P (-0.5 P pro Fehler)
7. `geschlecht = as.numeric(geschlecht)` 0.5 P
8. $t_n = 0.6928203 \not\leq -0.9541653 = -\lambda_{0.83}$, H_0 ablehnen bei $\alpha = 0.17\%$ 0.5 P + 0.5 P + 0.5 P
9. Anteil an weiblichen Benutzern ist geringer als 25%. 0.5 P
10. `p.value = function(geschlecht,p0,n){
 pnorm(sqrt(n)*(mean(geschlecht)-p0)/sqrt(p0*(1-p0)))
 }` 0.5 P (pnorm()) + 0.5 P korrekt