

Bachelorprüfung: Statistik Musterlösung

1. a) **(Total 1P)** Der Test muss gepaart sein, da zu jedem Läufer genau ein Wert mit jedem Schuhtyp vorliegt und die beiden Werte eines Läufers von dessen Lauffähigkeiten abhängen.
- b) **(Total 1P)** Nullhypothese: $H_0 : \mu_x = \mu_y$ **(1/2P)**
 Alternativhypothese: $H_A : \mu_x < \mu_y$ **(1/2P)**
- c) **(Total 3.5 P)**
1. **Modell:** Differenzen D_i i.i.d. $\sim \mathcal{N}(\mu = \mu_X - \mu_Y, \sigma^2)$, $i = 1, \dots, n$.
 2. **Nullhypothese** $H_0 : \mu_X = \mu_Y$, d.h. $\mu = 0$;
Alternativhypothese $H_A : \mu_X < \mu_Y$, d.h. $\mu < 0$.
 3. **Teststatistik:** $T = \frac{\sqrt{n}\hat{\mu}}{\hat{\sigma}}$ **(1 P)**
Verteilung der Teststatistik unter H_0 : $T \sim t_9$
 4. **Signifikanzniveau:** $\alpha = 0.05$
 5. **Verwerfungsbereich:**
 $K = (-\infty, -t_{9,1-\alpha}) = (-\infty, -1.833)$ **(1 P)**
 6. **Testentscheid:** $t = \frac{\sqrt{10} \cdot (-0.22)}{0.26} = -2.68 \in K$ **(0.5 P)**, also wird H_0 verworfen **(1 P)**
- d) **(Total 2.5 P)** Das einseitige Vertrauensintervall ist gegeben durch

$$\left(-\infty, \bar{x} - \bar{y} + t_{9,1-\alpha} \frac{\hat{\sigma}}{\sqrt{n}}\right) = \left(-\infty, -0.22 + 1.833 \cdot \frac{0.26}{\sqrt{10}}\right) = (-\infty, -0.069).$$

2. a) **(1 Punkt)** Anzahl gewonnener Pokerrunden durch Markus X ist $\text{Bin}(n, \pi)$.
 b) **(1 Punkt)** Daher ist

$$\mathbf{E}[X] = n\pi = 20 * 0.2 = 4 \text{ (1/2P)}$$

und

$$\text{Var}(X) = n\pi(1 - \pi) = 20 * 0.2 * 0.8 = 3.2, \text{ (1/2P)}$$

d.h. es werden 4 Siege von Markus erwartet.

- c) **(2 Punkte)** Verwende Zentralen Grenzwertsatz:

$$Y = \sum_{k=1}^{100} X_i \text{ (1/2P)}$$

$$Y \sim \mathcal{N}(20, 4^2) \text{ (1/2P)}$$

Daher ist

$$\begin{aligned} P[Y \geq 28] &= P\left[\frac{Y - 20}{4} \geq 2\right] = 1 - P[Z < 2] \text{ (1/2P)} \\ &= 1 - P[Z \leq 2] = 1 - 0.977 = 0.022 = 2.2\% \text{ (1/2P)} \end{aligned} \quad (1)$$

- d) 1. **Modell:** Y : Anzahl Siege von Markus; $Y \sim \text{Binomial}(n, \pi)$ mit $n = 100$
 2. **Nullhypothese** $H_0 : \pi = \pi_0 = 0.2$ (Markus spielt gleich gut wie die andern);
Alternativhypothese $H_A : \pi > 0.2$ (Markus spielt besser). **(0.5 P)**
 3. **Teststatistik:** $Z = \frac{Y - n\pi}{\sqrt{n\pi(1 - \pi)}} \text{ (0.5 P)}$
Verteilung der Teststatistik unter H_0 : $Z \approx \mathcal{N}(0, 1)$
 4. **Signifikanzniveau:** $\alpha = 0.01$
 5. **Verwerfungsbereich:**
 $K = [\Phi^{-1}(1 - \alpha), \infty) = [2.326, \infty) \text{ (0.5 P)}$
 6. **Testentscheid:** $Z = 2.000 \notin K$, daher wird die Nullhypothese *nicht* verworfen.
(0.5 P)

Das 99%-Quantil der Standard-Normalverteilung ist 2.326. Daher ist das 99%-Quantil der Verteilung von Y unter der Nullhypothese gleich $20 + 2.3 \cdot 4 = 29.3$: Markus müsste also mindestens 30 Mal gewinnen, damit die Nullhypothese verworfen würde. **(0.5 P)**

- e) **(2 Punkte)** Die geschätzte Gewinnwahrscheinlichkeit von Markus ist

$$\hat{\pi} = \frac{X}{n} = 0.28 \text{ (1P)}$$

Das zweiseitige 95% Vertrauensintervall von π ist

$$[\hat{\pi} \pm 1.96 \sqrt{\hat{\pi}(1 - \hat{\pi})/n}] = [0.28 \pm 1.96 \sqrt{0.28 * (1 - 0.28)/100}] = [0.192, 0.368] \text{ (1P)}$$

3. 1) **(1 Punkt)** Die Anzahl Beobachtungen n ist gegeben durch die Summe der Anzahl Freiheitsgrade und der Anzahl Parameter $n = n - p + p = 9 + 2 = 11$. Somit ist Antwort c) korrekt.
- 2) **(1 Punkt)** Der Intercept lässt sich schnell aus den Werten im angegebenen R-Output berechnen. Man multipliziert die t-Teststatistik mit der Standardabweichung und erhält so den Intercept. Das heisst, $51.25 \cdot -1.831 \approx -93.8$. Demnach ist Antwort b) richtig.
- 3) **(1 Punkt)** Um diese Frage zu beantworten betrachtet man den entsprechenden P-Wert. Ist der P-Wert kleiner als 0.05 wird die Nullhypothese auf dem 5% Niveau verworfen. Der P-Wert für $H_0 : \beta = 0$ und $H_A : \beta \neq 0$ ist, wie man aus dem R-Output erkennt, $0.00249 < 0.05$. Somit ist Antwort a) richtig.
- 4) **(1 Punkt)** Die t-Teststatistik lässt sich schnell aus den Werten im angegebenen R-Output berechnen. Die t-Teststatistik erhält man nämlich, indem man den geschätzten Wert durch seine Standardabweichung teilt. Somit ergibt sich $\frac{59.05}{14.24} \approx 4.15$. Richtig ist also Antwort d).
- 5) **(1 Punkt)** Das zweiseitige Vertrauensintervall für β ist gegeben durch $\hat{\beta} \pm t_{9;0.975} \cdot \hat{\sigma}_\beta$. Das Quantil $t_{9;0.975}$ lässt sich in der Tabelle der t-Verteilung nachschauen, es gilt $t_{9;0.975} = 2.262$. Somit ist Antwort d) korrekt.
- 6) **(1 Punkt)** Der Tukey-Anscombe Plot zeigt, dass die Annahme der konstanten Varianz der Fehler ϵ_i verletzt ist. Somit ist Aussage c) zutreffend.
- 7) **(1 Punkt)** Durch das Hinzufügen einer Beobachtung an der Stelle (2.5, 150) wird die Regressionsgerade flacher, das bedeutet $\hat{\beta}$ wird kleiner. Weiter wird $\hat{\sigma}$ grösser, da durch das Hinzufügen der Beobachtung die Residuen mehrheitlich dem Betrage nach grösser werden und somit auch $\hat{\sigma}$. Das heisst Antwort a) ist korrekt.
- 8) **(1 Punkt)** Bei der einfachen linearen Regression erhält man die empirische Korrelation zwischen erklärender Variable und Zielvariable aus der Wurzel von R^2 . Somit ist $\hat{\rho} = \sqrt{R^2} = \sqrt{0.6566} \approx 0.81$, also ist Antwort e) korrekt.
- 9) **(1 Punkt)** Die Nullhypotesen $H_{0,1} : \beta_1 = 0$ und $H_{0,2} : \beta_2 = 0$ werden nicht verworfen. Aber der F-Test hat einen kleinen P-Wert. Somit ist Antwort a) richtig.
- 10) **(1 Punkt)** In der multiplen Regression lässt sich R^2 nicht mehr als quadratische Stichprobenkorrelation zwischen erklärenden Variablen und Zielvariablen interpretieren. Somit ist Antwort b) richtig.

Übersicht

- 1) c)
- 2) b)
- 3) a)
- 4) d)
- 5) d)
- 6) c)
- 7) a)
- 8) e)

- 9) a)
10) b)
4. 1) b)
2) f)
 $X + Y = -2 + \frac{5}{4}X$. Also gilt $\mathbf{E}[X + Y] = -2 + \frac{5}{4}2 = 0.5$.
- 3) b)
Siehe 2: $X + Y = -2 + \frac{5}{4}X$. Also ist $\text{Var}(X + Y) = \frac{25}{16} \text{Var}(X) = \frac{25}{16}$. Bem.: X und Y sind nicht unabhängig, daher darf man die Varianzen nicht addieren!
- 4) c)
Zentraler Grenzwertsatz: Summe von vielen Zufallsvariablen ist (approx.) normalverteilt.
- 5) a)
Da die Teststatistik grösser 0 ist (d.h. sie "liegt auf der richtigen Seite") ist der p-Wert 0.01.