

Statistik I für Human- und Sozialwissenschaften

12. Übung

Lösungsvorschlag

Gruppenübung

G 40 Ein Friseur fragt sich, ob ein Zusammenhang zwischen Augenfarbe und Haarfarbe von Erwachsenen besteht. Er notiert sich dafür von 40 etwa gleichalten Kunden und Kundinnen seines Friseursalons deren Augen- und Haarfarbe. Es ergibt sich folgende Kontingenztafel für die absoluten Häufigkeiten:

| Haarfarbe / Augenfarbe | blau | braun | grün |
|------------------------|------|-------|------|
| blond | 16 | 5 | 2 |
| dunkel | 3 | 3 | 1 |
| rot | 1 | 2 | 7 |

Es wird angenommen, dass sich die Haarfarbe durch i.i.d. Zufallsvariablen X_1, \dots, X_n und die Augenfarbe durch i.i.d. Zufallsvariablen Y_1, \dots, Y_n beschreiben lassen.

- Formulieren Sie Nullhypothese und Alternativhypothese zur Untersuchung, ob Augenfarbe und Haarfarbe voneinander unabhängige Merkmale sind.
- Benennen Sie einen geeigneten Statistischen Test zur Überprüfung der aufgestellten Hypothesen.
- Führen Sie den in (b) genannten Statistischen Test auf dem Signifikanzniveau $\alpha = 0,01$ durch und interpretieren Sie das Ergebnis.

Nullhypothese:

H_0 : Haarfarbe und Augenfarbe sind voneinander unabhängige Merkmale;

Alternative H_1 : Haarfarbe und Augenfarbe sind voneinander abhängige Merkmale

Geeignetes Testverfahren: χ^2 -Unabhängigkeitstest.

Testgröße:

$$T(X_1, \dots, X_n, Y_1, \dots, Y_n) = \sum_{i=1}^k \sum_{j=1}^l \frac{(n_{i,j} - \frac{n_{i,\cdot} \cdot n_{\cdot,j}}{n})^2}{\frac{n_{i,\cdot} \cdot n_{\cdot,j}}{n}}$$

Kritischer Bereich:

Wir lehnen H_0 ab, falls gilt:

$$T(x_1, \dots, x_n, y_1, \dots, y_n) > \chi_{(k-1)(l-1); 1-\alpha}^2$$

Kontingenztafel
absoluten

für die
Häufigkeiten

| Haar / Augen | blau | braun | grün | Σ |
|--------------|------|-------|------|----------|
| blond | 16 | 5 | 2 | 23 |
| dunkel | 3 | 3 | 1 | 7 |
| rot | 1 | 2 | 7 | 10 |
| Σ | 20 | 10 | 10 | 40 |

Für die erwarteten Häufigkeiten $\frac{n_{i,\cdot} \cdot n_{\cdot,j}}{n}$ ergibt sich:

| Haar / Augen | blau | braun | grün |
|--------------|------|-------|------|
| blond | 11.5 | 5.75 | 5.75 |
| dunkel | 3.5 | 1.75 | 1.75 |
| rot | 5 | 2.5 | 2.5 |

Mit diesen beiden Tabellen berechnet sich die Testgröße wie folgt:

$$\begin{aligned}
 T(x_1, \dots, x_n, y_1, \dots, y_n) &= \frac{(16 - 11.5)^2}{11.5} + \frac{(5 - 5.75)^2}{5.75} + \frac{(2 - 5.75)^2}{5.75} \\
 &+ \frac{(3 - 3.5)^2}{3.5} + \frac{(3 - 1.75)^2}{1.75} + \frac{(1 - 1.75)^2}{1.75} \\
 &+ \frac{(1 - 5)^2}{5} + \frac{(2 - 2.5)^2}{2.5} + \frac{(7 - 2.5)^2}{2.5} \\
 &\approx 16.99.
 \end{aligned}$$

Mit $k = l = 3$ und $\alpha = 0.1$ lesen wir aus der Tabelle ab:

$$\chi^2_{(k-1)(l-1); 1-\alpha} = \chi^2_{2; 2; 1-0.01} = \chi^2_{4; 0.99} = 13.28$$

Wegen $16.99 > 13.28$ lehnen wir H_0 ab, d.h. wir haben einen Zusammenhang zwischen Augenfarbe und Haarfarbe.

- G 41** Gegeben sei folgende geordnete Messreihe: 0.1; 0.7; 0.7; 2.1; 2.6; 2.6; 2.6; 2.6; 2.7; 7.4 7.4; 7.4; 7.4; 8.2; 8.6; 9.0; 9.0; 9.3; 9.7.

Testen Sie zu einem Signifikanzniveau $\alpha = 0.1$, ob die Daten als gleichverteilt auf dem Intervall $[0; 10]$ aufgefasst werden können. Eine solche Gleichverteilung besitzt die Verteilungsfunktion

$$F_0(x) = \begin{cases} 0 & x < 0 \\ \frac{1}{10}x & 0 \leq x \leq 10 \\ 1 & 1 < x. \end{cases}$$

- (a) Mithilfe des Kolmogorow Smirnow Test. (Das 0.9-Quantil der Kolmogorow-Smirnow-Verteilung $k_{0.9}^{20} = 0.26473$.)
 (b) Mithilfe des χ^2 -Anpassungstest unter Benutzung der Klasseneinteilung $[0; 2.5)$, $[2.5; 5)$, $[5; 7.5)$ und $[7.5; 10]$.

Nullhypothese H_0 : Daten sind gleichverteilt. Alternativhypothese H_1 : Daten sind nicht gleichverteilt.

- (a) Die Testgröße berechnet sich durch den größten Abstand zwischen der empirischen Verteilungsfunktion der Messdaten F_n und der vermuteten Verteilungsfunktion F_0 .

$$T(X_1, \dots, X_n) = \max_{i=1, \dots, n} (\max \{ |F_0(x_{(i)}) - F_n(x_{(i)})|; |F_0(x_{(i)}) - F_n(x_{(i-1)})| \})$$

$$F_{20}(x) := \begin{cases} 0 & \text{für } x < 0.1 \\ 0.05 & \text{für } 0.1 \leq x < 0.7 \\ 0.15 & \text{für } 0.7 \leq x < 2.1 \\ 0.2 & \text{für } 2.1 \leq x < 2.6 \\ 0.4 & \text{für } 2.6 \leq x < 2.7 \\ 0.45 & \text{für } 2.7 \leq x < 7.4 \\ 0.7 & \text{für } 7.4 \leq x < 8.2 \\ 0.75 & \text{für } 8.2 \leq x < 8.5 \\ 0.8 & \text{für } 8.5 \leq x < 9.0 \\ 0.9 & \text{für } 9.0 \leq x < 9.3 \\ 0.95 & \text{für } 9.3 \leq x < 9.7 \\ 1 & \text{für } 9.7 \leq x. \end{cases}$$

| $x_{(i)}$ | $F_0(x_{(i)})$ | $F_n(x_{(i)})$ | $ F_0(x_{(i)}) - F_n(x_{(i)}) $ | $ F_0(x_{(i)}) - F_n(x_{(i-1)}) $ |
|-----------|----------------|----------------|---------------------------------|-----------------------------------|
| 0.1 | 0.01 | 0.05 | 0.04 | 0.01 |
| 0.7 | 0.07 | 0.15 | 0.08 | 0.02 |
| 2.1 | 0.21 | 0.2 | 0.01 | 0.06 |
| 2.6 | 0.26 | 0.4 | 0.14 | 0.06 |
| 2.7 | 0.27 | 0.45 | 0.18 | 0.13 |
| 7.4 | 0.74 | 0.7 | 0.04 | 0.29 |
| 8.2 | 0.82 | 0.75 | 0.07 | 0.12 |
| 8.5 | 0.85 | 0.8 | 0.05 | 0.1 |
| 9.0 | 0.9 | 0.9 | 0 | 0.1 |
| 9.3 | 0.93 | 0.95 | 0.02 | 0.03 |
| 9.7 | 0.97 | 1 | 0.03 | 0.02 |

Der Wert der Testgröße ergibt sich als das Maximum der letzten beiden Spalten der Tabelle. $T(x_1, \dots, x_{20}) = 0.29$.

H_0 wird abgelehnt, falls $T(x_1, \dots, x_n) \geq k_{1-\alpha}^n$ ist. Wegen

$$T(x_1, \dots, x_{20}) = 0.29 > 0.26473 = k_{0.9}^{20} = k_{1-0.1}^{20}$$

lehnen wir H_0 ab.

(b) Testgröße:
$$T(X_1, \dots, X_n) = \sum_{i=1}^k \frac{(n_i - np_i)^2}{np_i}$$

Ablehnung von H_0 :
$$T(x_1, \dots, x_n) > \chi_{k-1; 1-\alpha}^2$$

Es liegen 4 Klassen mit den Häufigkeiten $n_1 = 4$, $n_2 = 5$, $n_3 = 5$ und $n_4 = 6$ vor. Die erwarteten relativen Anzahlen der Klassen berechnen sich durch $p_i = P(Y \in \text{Klasse } i)$, wobei Y eine Zufallsvariable mit Verteilung F_0 sei. Daraus folgt:

$$p_1 = P(Y \in \text{Klasse 1}) = P(0 \leq Y < 2.5) = F_0(2.5) - F_0(0) = \frac{1}{10} \cdot 2.5 - \frac{1}{10} \cdot 0 = 0.25.$$

Analog erhält man $p_1 = p_2 = p_3 = p_4 = 0.25$. Damit ergibt sich als Wert der Testgröße

$$T(x_1, \dots, x_{20}) = \frac{(4 - 20 \cdot 0.25)^2}{20 \cdot 0.25} + \frac{(5 - 20 \cdot 0.25)^2}{20 \cdot 0.25} + \frac{(5 - 20 \cdot 0.25)^2}{20 \cdot 0.25} + \frac{(6 - 20 \cdot 0.25)^2}{20 \cdot 0.25} = \frac{2}{5} = 0.4$$

Wegen

$$T(x_1, \dots, x_{20}) = 0.4 < 6.25 = \chi_{3; 0.9}^2 = \chi_{k-1; 1-\alpha}^2$$

kann H_0 nicht abgelehnt werden.