

9 Signifikanztests Teil III

Zoltán Zomotor

Versionsstand: 12. April 2016, 11:29

Die nummerierten Felder bitte während der Vorlesung ausfüllen.



This work is licensed under the Creative Commons Attribution-NonCommercial-ShareAlike 3.0 Germany License. To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc-sa/3.0/de/> or send a letter to Creative Commons, 171 Second Street, Suite 300, San Francisco, California, 94105, USA.

Bitte hier notieren, was beim Bearbeiten unklar geblieben ist:

Inhaltsverzeichnis

1	Kontingenztest	1
2	Korrelationstest	5

1 Kontingenztest¹

- Gegeben: Zwei verbundene einfache Stichproben

X_1, \dots, X_n und Y_1, \dots, Y_n

- Hypothesenpaar:

H_0 : Die Merkmale X und Y sind ² in G unabhängig

¹Bedeutung von „Kontingenz“ (duden.de): Häufigkeit bzw. Grad der Wahrscheinlichkeit des gemeinsamen Auftretens zweier Sachverhalte, Merkmale usw.

H_1 : Die Merkmale X und Y sind $\overset{3}{}$ in G abhängig

• Vorgehensweise entspricht dem $\overset{4}{}$ χ^2 -Anpassungstest

• basiert aber auf $\overset{5}{}$ einer Kontingenztabelle

• Vorgehen:

Schritt 1: Ein Signifikanzniveau $\overset{6}{}$ α festlegen.

Schritt 2: Den Testfunktionswert folgendermaßen ermitteln:

2.1 Die x -Achse in $k \geq 2$ und die y -Achse in $\ell \geq 2$ disjunkte, aneinander angrenzende

Intervalle $\overset{7}{}$ A_1, \dots, A_k bzw. B_1, \dots, B_ℓ unterteilen.

2.2 Eine Kontingenztabelle mit Randhäufigkeiten erstellen:

		Y				
		B_1	B_2	...	B_ℓ	
X	A_1	h_{11}	h_{12}	...	$h_{1\ell}$	h_{A_1}
	A_2	h_{21}	h_{22}	...	$h_{2\ell}$	h_{A_2}
	\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
	A_k	h_{k1}	h_{k2}	...	$h_{k\ell}$	h_{A_k}
		h_{B_1}	h_{B_1}	...	h_{B_ℓ}	$\overset{8}{}$ n

Dabei bezeichnen $\overset{9}{}$ h_{ij} , h_{A_i} und h_{B_j} die Anzahl der beobachteten Paa-

re $\overset{10}{}$ (x, y) in $A_i \times B_j$, A_i und B_j .

2.3 Zu jeder Kombination aus $i = 1, \dots, k$ und $j = 1, \dots, \ell$ die Größe

$\overset{11}{}$ $\tilde{h}_{ij} = h_{A_i} \cdot h_{B_j} / n$ berechnen.

2.4 Den Testfunktionswert v folgendermaßen berechnen:

$$\overset{12}{}$$

$$v = \sum_{i=1}^k \sum_{j=1}^{\ell} \frac{(h_{ij} - \tilde{h}_{ij})^2}{\tilde{h}_{ij}} = \sum_{i=1}^k \sum_{j=1}^{\ell} \frac{h_{ij}^2}{\tilde{h}_{ij}} - n$$

Schritt 3: Mit dem Fraktilwert $x_{1-\alpha}$ der $\chi^2((k-1) \cdot (\ell-1))$ -Verteilung den Verwerfungsbereich $B = (x_{1-\alpha}, \infty)$ festlegen.

Schritt 4: H_0 genau dann ablehnen, wenn $v \in B$ gilt.

• Bemerkungen:

(i) Test ist nur anwendbar, wenn

$$h_{ij} \geq 5 \text{ bzw. } \tilde{h}_{ij} \geq 5 \text{ für alle } i, j$$

Falls nicht erfüllt \Rightarrow Intervalle zusammenlegen!

(ii) Falls diskrete Verteilungen:

- pro Ausprägung ein Intervall (falls (i) erfüllt)
- Schritt 2.1 entfällt

(iii) Falls $k = \ell = 2$:

- Schritt 2.3: kann entfallen
- Schritt 2.4: Berechne Testfunktionswert gemäß

$$v = \frac{n(h_{11}h_{22} - h_{12}h_{21})^2}{h_{A_1}h_{A_2}h_{B_1}h_{B_2}}$$

(iv) Falls Randwahrscheinlichkeiten $p_i = P(X \in A_i)$, $q_j = P(Y \in B_j)$ bekannt:

- Schritt 2.2: Randhäufigkeiten entfallen

- Schritt 2.3: Ersetze \tilde{h}_{ij} durch $n \cdot p_i \cdot q_j$

- Schritt 3: Ersetze $\chi^2((k-1) \cdot (\ell-1))$ durch $\chi^2(k \cdot \ell - 1)$

- Beispiel: Eine regionale Tageszeitung lässt per Telefon ihre Leser befragen, wie gut sie sich durch die Zeitung informiert fühlen. Zur Auswahl stehen die Antworten gut, mäßig, schlecht. Außerdem wurde nach dem Alter des Urteilenden gefragt. Hier das Ergebnis:

		Bewertung		
		gut	mäßig	schlecht
Alter	unter 20	24	11	5
	20 bis 40	32	17	11
	über 40	64	22	14

Ist die Meinung der Leser über ihre Zeitung mit dem Signifikanzniveau $\alpha = 0.01$ signifikant vom Alter abhängig? $\Rightarrow H_0$: „Alter und Meinung sind voneinander unabhängig“

1. $\alpha = 0.01$

2. 2.1 Diskrete Verteilung, A_j, B_j gegeben

2.2

h_{ij}				
	24	11	5	²² 40
	32	17	11	60
	64	22	14	100
	²³ 120	50	30	²⁴ 200

2.3

\tilde{h}_{ij}				
	24	10	6	40
	36	15	9	60
	60	25	15	100
	120	50	30	200

2.4

$$v = \frac{24^2}{24} + \frac{11^2}{10} + \frac{5^2}{6} + \frac{32^2}{36} + \frac{17^2}{15} + \frac{11^2}{9} + \frac{64^2}{60} + \frac{22^2}{25} + \frac{14^2}{15} - 200 = 2.1$$

3. $\chi^2((3-1) \cdot (3-1)) = \chi^2(4): x_{1-\alpha} = x_{0.99} = 13.28 \Rightarrow B = (9.2, \infty)$

4. $v \notin B \Rightarrow H_0$ beibehalten.

Die Meinung hängt somit ²⁹ nicht signifikant vom Alter ab.

2 Korrelationstest

- Gegeben: Zwei verbundene einfache Stichproben

$$X_1, \dots, X_n \text{ und } Y_1, \dots, Y_n$$

mit

$$X_i \sim N(\mu_1, \sigma_1) \text{ und } Y_i \sim N(\mu_2, \sigma_2)$$

- Hypothesenpaare:

$$\text{a) } H_0: \rho = 0 \quad , \quad H_1: \rho \neq 0$$

$$\text{b) } H_0: \rho = 0 \text{ (oder } \rho \geq 0), H_1: \rho < 0$$

$$\text{c) } H_0: \rho = 0 \text{ (oder } \rho \leq 0), H_1: \rho > 0$$

- Vorgehen:

Schritt 1: Ein Signifikanzniveau ³³ α festlegen.

Schritt 2: Mit Hilfe des empirischen oder Stichproben-Korrelationskoeffizienten

$$r = \frac{s_{xy}}{s_x \cdot s_y} \text{ mit der Stichproben-Kovarianz}$$

$$s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y}) = \frac{1}{n-1} \left(\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} \right)$$

der Beobachtungspaare (x_i, y_i) , $i = 1, \dots, n$ den Testfunktionswert v berechnen:

$$v = \sqrt{n-2} \frac{r}{\sqrt{1-r^2}}$$

Schritt 3: Den Verwerfungsbereich festlegen:

$$B = (-\infty, -X_{1-\alpha/2}) \cup (x_{1-\alpha/2}, \infty)$$

Lücke 32 Fall a)

$$B = (-\infty, -X_{1-\alpha})$$

Lücke 32 Fall b)

$$B = (x_{1-\alpha}, \infty)$$

Lücke 32 Fall c)

Fraktilswerte $x_{1-\alpha/2}$ bzw. $x_{1-\alpha}$ der $t(n-2)$ -Verteilung entnehmen.

Schritt 4: H_0 genau dann verwerfen, wenn $v \in B$ gilt

- Beispiel ([BV12, Aufgabe 3.3.11]): In einer Behörde wurde an 25 zufällig ausgewählten Arbeitstagen des Jahres 2009 jeweils die Gesamtlänge Y aller abgehenden Telefonate ermittelt (in Minuten). Um die Abhängigkeit der „Telefonierfreudigkeit“ vom Wetter zu untersuchen, wurde an diesen Tagen zusätzlich um 13 Uhr der Luftdruck X registriert (in Hektopascal). Aus den $n = 25$ Beobachtungspaaren sind dann

- die empirischen Varianzen $s_x^2 = 94.09$ bzw. $s_y^2 = 1\,263\,376$ und
- die empirische Kovarianz $s_{xy} = 3925$

berechnet worden.

- Unterstellen Sie normalverteilte Beobachtungen und prüfen Sie, ob die Gesprächsdauer signifikant ($\alpha = 0.05$) vom Luftdruck abhängt.
- Was bedeutet der empirische Korrelationskoeffizient in der vorliegenden Situation?

- Hypothesenpaar: $H_0: \rho = 0, H_1: \rho \neq 0$

1. $\alpha = 0.05$

2.
$$r = \frac{s_{xy}}{s_x s_y} = \frac{3925}{\sqrt{94.09} \cdot \sqrt{1\,263\,376}} = 0.36$$

$$v = \sqrt{n-1} \frac{r}{\sqrt{1-r^2}} = \sqrt{23} \cdot \frac{0.36}{\sqrt{1-0.36^2}} \approx 1.85$$

3.
$$t(n-2) = t(23): x_{1-\alpha/2} = x_{0.975} = 2.07$$

$$\Rightarrow B = (-\infty, -2.07) \cup (2.07, \infty)$$

4. $v \notin B \Rightarrow H_0$ beibehalten.

Es lässt sich somit nicht nachweisen, dass die Gesprächsdauer signifikant vom Luftdruck abhängt.

⁴⁵ Leichte Abhängigkeit zwischen X und Y .
Bedeutung von r : $r > 0 \Leftrightarrow$ Je höher der Luftdruck, um so länger wird telefoniert.

Literatur

- [BV12] Udo Bankhofer und Jürgen Vogel. *Übungsbuch Datenanalyse und Statistik*. Springer Gabler, 2012.