


Chi-Quadrat Anpassungstest & Unabhängigkeitstest

- Induktive Statistik
- Eingeführt von Helmert (1876) & Pearson (1900)

Formale Definition:

Sind $X_i (i=1, 2, \dots, n)$ stochastisch unabhängige und $N(0; 1)$ -verteilte ZV, dann genügt die ZV $Y^2 = X_1^2 + X_2^2 + \dots + X_n^2$, die sich aus der Summe der n quadrierten ZV X_i^2 ergibt, einer Chi-Quadrat-Verteilung mit $\nu = n$ Freiheitsgraden.

Dichte & Verteilungsfunktion (für $\nu=5$)



Die Dichte f_n der χ_n^2 -Verteilung mit n Freiheitsgraden hat die Form:

$$f_n(x) = \begin{cases} \frac{x^{\frac{n}{2}-1} e^{-\frac{x}{2}}}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

Dabei steht $\Gamma(r)$ für die [Gammfunktion](#). Die Werte von $\Gamma(\frac{n}{2})$ kann man auch berechnen mit

$$\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}, \quad \Gamma(1) = 1, \\ \Gamma(r+1) = r \cdot \Gamma(r) \text{ mit } r \in \mathbb{R}^+.$$

Erwartungswert; Varianz und die Approximationsmöglichkeiten:

$$E(Y) = v$$
$$\text{Var}(Y) = 2v$$

Approximationsmöglichkeiten:

$$Y \sim \chi^2(v)$$


a) $v \geq 30 \Rightarrow Z = \frac{\sqrt{2Y} - \sqrt{2v-1}}{1}$
näherungsweise standardnormalverteilt

b) $v \geq 100 \Rightarrow N(v; 2v)$

Das Quantil teilt die Dichte- und Verteilungsfunktion in 2 Teilbereiche.

Einmal alle Werte zwischen 0-11,07 die mit einer Möglichkeit von 95% auftreten und alle Werte größer 11,06 die mit einer Möglichkeit von 5% auftreten.

Diese 5% nennt man auch Signifikanzniveau oder Irrtumsmöglichkeit. Den Wert 11,07 kann man entweder von der Verteilungsfunktion ablesen oder von der Chi-Quadrat-Verteilungstabelle mit $v=5$ und $p=0,95$.



Chi-Quadrat-Anpassungstest

- Vergleich unserer Stichprobe mit einer hypothetischen
-> also liegt hier eine bestimmte Verteilung vor?
- Vorgehensweise:

1. Aufgabenstellung

→ Zufallsstichprobe (X_1, X_2, \dots, X_n)

→ Überprüfung, ob Verteilung $F_x(x)$ mit hypothetischer Verteilung $F_0(x)$ übereinstimmt

2. Voraussetzungen

→ zufällige Entnahme der Stichprobenelemente

3. H_0

$$H_0: F_x(x) = F_0(x)$$

$$H_0: f_x(x) = f_0(x)$$

4. Testgröße

$$\chi^2_* = \sum_{j=1}^m \frac{(h_{oj} - h_{ej})^2}{h_{ej}} \quad h_{ej} = n f_0(x_j)$$

$$\chi^2_* \sim \chi^2(m-1)$$

5. Annahmekennzahlen

$$c_0 = \chi^2(1-\alpha, m-1)$$

6. Testentscheidung

Ablehnung H_0 , falls:

$$\chi^2_* > c_0$$

h_{oj} = beobachtete Werte

h_{ej} = erwartete Werte

m = Anzahl der Klassen (Z.B. beim Würfel gibt es 6 mögliche Ereignisse, also wäre hier $m=6$)

Chi-Quadrat-Unabhängigkeitstest

- Wollen Herausfinden ob die Merkmale X und Y stochastisch unabhängig sind
- Vorgehensweise:

1. Aufgabenstellung
→ Zufallsstichprobe $(X_1, Y_1), \dots, (X_n, Y_n)$
→ Überprüfung ob X und Y unabhängig sind
→ 2D-Verteilung:
m Zeilen (x_1, \dots, x_m)
q Spalten (y_1, \dots, y_q)

2. Voraussetzungen
→ zufällige Entnahme der Stichprobenelemente $(x_i, y_i), i=1, \dots, n$

3. H_0
 H_0 : Merkmale X und Y sind unabhängig voneinander

4. Testgröße

$$\chi^2_* = \sum_{j=1}^m \sum_{k=1}^q \frac{(n_{ojk} - h_{ejk})^2}{h_{ejk}}$$
$$\chi^2_* = \chi^2 (m-1)(q-1)$$

5. Annahmekennzahl
 $C_0 = \chi^2 (1-\alpha; (m-1)(q-1))$

6. Testentscheidung
Ablehnung H_0 , falls:
 $\chi^2_* > C_0$

h_{jk} = beobachtete Werte

h_{jk} = erwarteten Werte (erst, wenn die Randsummen gegeben sind können wir diese Werte berechnen. Weil wir unter anderem davon ausgehen, dass die erwarteten Werte stochastisch unabhängig sind)

formal : $h_{jk} = (h_{+k} * h_{j+}) / n$, wobei h_{+k} und h_{j+} , die oben erwähnten Randsummen sind.

m = Anzahl der Klassen für das Merkmal X

q = Anzahl der Klassen für das Merkmal Y