

# Anpassungstests

Anpassungstests prüfen, wie sehr sich ein bestimmter Datensatz einer erwarteten Verteilung anpasst bzw. von dieser abweicht. Nach der Erläuterung der Funktionsweise sind je ein Beispiel zur Prüfung auf Gleich- und auf Normalverteilung angeführt.

## VORGEHENSWEISE

Jenes Intervall, in dem die Messwerte theoretisch liegen können, wird in  $m$  Teilbereiche aufgespalten. Üblicherweise wählt man die Unterteilung so, dass sich gleich große Intervalle ergeben. Ausnahmen sind bei der NV der erste (beginnt bei  $-\infty$ ) und der letzte Bereich (geht bis  $+\infty$ ).

Anschließend werden für jeden Teilbereich die Werte  $o_j$  („observed frequencies“= beobachtete Häufigkeiten) und  $e_j$  („estimated frequencies“= erwartete Häufigkeiten) ermittelt.

$o_j \dots$  Anzahl der gemessenen Werte, die in den  $j$ -ten Bereich fallen

$n \dots$  Gesamtzahl der Messwerte

$p_j \dots$  Wahrscheinlichkeit (gemäß der erwarteten Verteilung), dass ein gemessener Wert im  $j$ -ten Intervall liegt

$e_j = n \cdot p_j$  Anzahl der Werte, die - bei Zutreffen der erwarteten Verteilung - im  $j$ -ten Bereich liegen müssten

## *Aufstellen der Hypothesen*

$H_0 \dots$  Die Erwartung trifft zu. (Die Daten weichen von der erwarteten Verteilung nicht überzufällig ab.)

$H_1 \dots$  Die Erwartung trifft nicht zu. (Die vorliegende Verteilung unterscheidet sich signifikant von der erwarteten.)

### ***Prüfgröße***

Berechnung für ganzzahlige  $e_j$ :

$$\chi^2 = \sum_{j=1}^m \frac{(o_j - e_j)^2}{e_j}$$

Meistens sind die  $e_j$  nicht ganzzahlig. Dann ist die Verwendung folgender Umformung vorteilhaft (selbes Resultat, aber angenehmer zu rechnen):

$$\chi^2 = \frac{1}{n} \sum_{j=1}^m \frac{o_j^2}{p_j} - n$$

### ***Freiheitsgrade***

Beim Test auf Gleichverteilung werden die  $e_j$  durch eine Bedingung eingeschränkt: Die Summe der erwarteten Werte muss gleich der Anzahl der Messwerte sein ( $\sum_{j=1}^m e_j = n$ ), daher:  $df = m - 1$ .

Beim Test auf Normalverteilung gilt  $df = m - 1$  nur, falls die Parameter ( $\mu$  und  $\sigma$ ) der erwarteten Verteilung von vornherein (unabhängig von den Daten) bekannt sind. Müssen diese anhand der vorliegenden Werte geschätzt werden, so „kostet“ das je einen Freiheitsgrad. In diesem Fall gilt also:  $df = m - 3$ .

### ***Vergleich mit dem kritischen Wert***

Der kritische  $\chi^2$ -Wert ist aus der Tabelle abzulesen. Die  $H_1$  ist hier immer einseitig (nur große Abweichungen von Interesse).

## BSP. 1: PRÜFUNG AUF GLEICHVERTEILUNG

### *Ausgangssituation*

$n = 200$  Studierende wählen die/den beliebteste/-n von vier ProfessorInnen. Das Ergebnis lautet:

<i>Prof. Auer</i>	45 Stimmen
<i>Prof. Braun</i>	62 St.
<i>Prof. Claus</i>	37 St.
<i>Prof. Daum</i>	56 St.

### *Fragestellung*

Kann man aufgrund der Daten davon ausgehen, dass die vier ProfessorInnen gleich beliebt sind?

### *Aufstellen der Hypothesen*

$H_0 \dots$  alle 4 gleich beliebt

$H_1 \dots$  Beliebtheit nicht gleich verteilt

### *Berechnen der Prüfgröße*

$j$	$o_j$	$e_j$	$o_j - e_j$	$(o_j - e_j)^2$	$\frac{(o_j - e_j)^2}{e_j}$
1	45	50	-5	25	0.5
2	62	50	12	144	2.88
3	37	50	-13	169	3.38
4	56	50	6	36	0.72
	200	200	0	374	7.48

$$\chi^2 = \sum_{j=1}^m \frac{(o_j - e_j)^2}{e_j} = 7.48$$

### ***kritischer Wert***

$$df = 4 - 1 = 3$$

$$\alpha = 0.05$$

Fragestellung einseitig

$$\Rightarrow \chi_{krit.}^2 = 7.82$$

### ***Signifikanz***

Da  $\chi^2 = 7.48 < 7.82 = \chi_{krit.}^2$  ist der Test (knapp) nicht signifikant. Die  $H_0$  muss also beibehalten werden, d.h. aufgrund der Daten kann man nicht davon ausgehen, dass ein überzufälliger Unterschied in der Beliebtheit der Professoren besteht.

## **BSP. 2: PRÜFUNG AUF NORMALVERTEILUNG**

### ***Ausgangssituation, Fragestellung***

Ein Datensatz von  $n = 100$  Messwerten zum durchschnittlichen wöchentlichen Fernsehkonsum Jugendlicher soll auf Normalverteilung geprüft werden, um geeignete Tests für weiteres Analysieren der Daten auswählen zu können.

*Die einzelnen Werte werden hier nicht extra aufgelistet. In der Tabelle (unten) ist ersichtlich, wieviele Jugendliche in welchem Bereich liegen.*

### ***Aufstellen der Hypothesen***

$H_0$  ... die Werte sind normalverteilt

$H_1$  ... die Werte sind nicht normalverteilt

### ***Berechnen der Prüfgröße***

Zunächst werden Mittelwert und Standardabweichung berechnet:

$$\bar{x} = 12.8 \quad s_x = 5.7$$

Als Klassenbreite wird  $2 h$  gewählt, wobei die erste Klasse bis  $6 h$  geht und die letzte bei  $20 h$  beginnt.

Um die erwarteten Werte ermitteln zu können, werden die Klassengrenzen standardisiert. In der Tabelle werden jeweils die oberen standardisierten Klassengrenzen ( $v_j^*$ ) angegeben. Mit Hilfe der  $z$ -Tabelle können dann die Wahrscheinlichkeiten  $p_j$  ermittelt werden. Da die zweite der oben genannten Formeln angewendet wird, kann auf die effektive Berechnung der erwarteten Werte  $e_j$  verzichtet werden.

$j$	Bereich	$o_j$	$v_j^*$	$p_j$	$o_j^2$	$\frac{o_j^2}{p_j}$
1	bis 6	11	-1.19	0.1170	121	1034.19
2	]6; 8]	15	-0.84	0.0835	225	2694.61
3	]8; 10]	8	-0.49	0.1116	64	573.48
4	]10; 12]	7	-0.14	0.1322	49	370.65
5	]12; 14]	16	0.21	0.1389	256	1843.05
6	]14; 16]	10	0.56	0.1291	100	774.59
7	]16; 18]	12	0.91	0.1063	144	1354.66
8	]18; 20]	6	1.26	0.0776	36	463.92
9	ab 20	15	$\infty$	0.1038	225	2167.63
		100		1.0000		11276.78

### **Prüfgröße**

$$\chi^2 = \frac{1}{n} \sum_{j=1}^m \frac{o_j^2}{p_j} - n$$

$$\chi^2 = \frac{1}{100} \cdot 11276.78 - 100 = 12.7678$$

$$(df = 9 - 3 = 6)$$

### ***Signifikanz***

Der kritische  $\chi^2$ -Wert für  $df = 6$  ist mit Hilfe der Tabelle zu ermitteln.  
Für dieses Beispiel gilt:

$$\chi_{krit.}^2 = 12.59$$

Die Prüfgröße ist (knapp) größer als  $\chi_{krit.}^2$  und somit *signifikant*. Die Daten sind nicht normalverteilt.