

# Kontingenztafeln

Ein ähnliches Prinzip wie bei der Prüfung auf Gleich- bzw. Normalverteilung wird auch beim Vergleich zweier qualitativer, mehrkategoriel- ler („polytomer“) Variablen angewendet. Hierfür werden die Messwerte in einer  $c \times r$ -Tabelle („Kontingenztafel“) aufgelistet, wobei die  $c$  Spalten den verschiedenen Ausprägungen der ersten und die  $r$  Reihen den Kategorien der zweiten Variablen entsprechen.

## VORAUSSETZUNGEN

- 1.) Die Eintragungen sind absolute Häufigkeiten.
- 2.) Jeder Fall (jede Vp) geht nur einmal in die Daten ein.
- 3.) Alle Eintragungen sind wechselseitig unabhängig.
- 4.) Die erwarteten Werte sollten nicht zu klein sein ( $e_{ij} \geq 5$ ), da sonst die  $\chi^2$ -Verteilung nicht gut genug angenähert wird.

## VORGEHENSWEISE

### *Hypothesen*

$H_0$  ... Die Verteilungen der beiden Stichproben sind gleich.

$H_1$  ... Die beiden Verteilungen sind unterschiedlich.

### *absolute Häufigkeiten*

Ermittlung der Summen für jede Kategorie:

$n$  ... Gesamtzahl der Einträge

$n_i$  ... Zeilensummen

$n_j$  ... Spaltensummen

$r$  ... Anzahl der Reihen („rows“)

$c$  ... Anzahl der Spalten („columns“)

$o_{11}$	$o_{12}$	$\dots$	$o_{1c}$	$n_{1.}$
$o_{21}$	$o_{22}$	$\dots$	$o_{2c}$	$n_{2.}$
$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
$o_{r1}$	$o_{r2}$	$\dots$	$o_{rc}$	$n_{r.}$
$n_{.1}$	$n_{.2}$	$\dots$	$n_{.c}$	$n$

**Die erwarteten Werte**

Die  $e_{ij}$  werden anhand der Randsummen bestimmt:

$$e_{ij} = \frac{n_{i.} \cdot n_{.j}}{n}$$

*Herleitung:*

Die relativen Häufigkeiten sind  $\frac{n_{.j}}{n}$  für die Spalten und  $\frac{n_{i.}}{n}$  für die Zeilen. Um den erwarteten Anteil für eine bestimmte Kombination „Zeile  $\times$  Spalte“ zu berechnen, werden diese einfach multipliziert ( $\rightarrow \frac{n_{i.}}{n} \cdot \frac{n_{.j}}{n} = \frac{n_{i.} \cdot n_{.j}}{n^2}$ ). Für den erwarteten absoluten Wert ( $e_{ij}$ ) muss diese relative Häufigkeit mit der Gesamtzahl der Werte ( $n$ ) multipliziert werden, was - nach Kürzen - obigen Term  $\frac{n_{i.} \cdot n_{.j}}{n}$  ergibt.

*Anmerkung:*

Die Werte der letzten Zeile bzw. Spalte können auch berechnet werden, indem man von der jeweiligen Randsumme alle anderen Werte (der entsprechenden Zeile/Spalte) subtrahiert.

**Testgröße**

$$\chi^2 = \sum_{ij} \frac{(o_{ij} - e_{ij})^2}{e_{ij}}$$

mit  $df = (r - 1) \cdot (c - 1)$

**Signifikanzprüfung**

Verglichen wird diese Prüfgröße mit dem kritischen Wert (für  $\alpha$ ,  $df = (r - 1) \cdot (c - 1)$ , einseitige Fragestellung) aus der Tabelle. Die  $H_0$  wird verworfen, falls  $\chi^2 > \chi_{krit.}^2$ .

## KONTINGENZKOEFFIZIENT

Man kann obige Hypothesen auch folgendermaßen interpretieren:

$H_0$  ... Es besteht kein Zusammenhang zwischen den untersuchten Variablen.

$H_1$  ... Die beiden Variablen hängen zusammen.

Es wäre wünschenswert – insbesondere, falls der Test signifikant ist – ein Maß für die Stärke des Zusammenhangs zur Verfügung zu haben. Bei quantitativen Variablen ist dies die Korrelation, für qualitative Merkmale lernen wir nun den *Kontingenzkoeffizient* („coefficient of contingency“,  $CC$ ) kennen:

### *Berechnung von $CC$*

$$CC = \sqrt{\frac{\chi^2}{\chi^2 + n}}$$

### *Korrektur: $CC \rightarrow CC^*$*

Für  $m = \min(r, c)$  ist der maximale Wert, den  $CC$  annehmen kann:

$$CC_{max} = \sqrt{\frac{m-1}{m}}$$

Damit verschiedene Kontingenzkoeffizienten auch miteinander vergleichbar bleiben, setzt man die  $CC$ -Werte in Relation zu den maximal erreichbaren Werten  $CC_{max}$ :

$$CC^* = \frac{CC}{CC_{max}}$$

### ***Eigenschaften, Unterschiede zur Korrelation***

a) Der Kontingenzkoeffizient ist (im Gegensatz zur Korrelation) immer positiv. Man kann also am  $CC^*$ -Wert nicht erkennen, in welche Richtung der Zusammenhang geht, sondern nur, wie stark dieser ist.

b) Der Kontingenzkoeffizient ist immer *kleiner* als 1. Im Gegensatz dazu kann die Korrelation auch den Wert 1 annehmen.

c) Das Quadrat der (Produktmoment-)Korrelation kann als Bestimmtheitsmaß („erklärter Varianzanteil“) interpretiert werden. Für das Quadrat des Kontingenzkoeffizienten gibt es keine vergleichbare Interpretationsmöglichkeit.