

Statistik

Eine verständliche Einführung

VS Verlag für Sozialwissenschaften, 274 Seiten, 2010



Formelsammlung

korrigierte Fassung vom 01.02.2011

Korrekturen gegenüber dem Buch sind rot markiert

Kapitel 2 - Häufigkeitsverteilungen und ihre grafischen Darstellungen

Berechnung von Prozenten (S. 35)

$${}_{\%}k = \frac{f(k)}{n} \cdot 100\%$$

$f(k)$ = absolute Häufigkeit in der Kategorie k
 n = Anzahl der Fälle

Berechnung von gültigen Prozenten (S. 36)

$${}_{\%}k = \frac{f(k)}{n_g} \cdot 100\%$$

$f(k)$ = absolute Häufigkeit in der Kategorie k
 n_g = Anzahl der Fälle mit gültigen Werten

Berechnung von kumulierten Prozenten (S. 36)

$${}_{\%}k_{\text{kum}} = \frac{f_{\text{kum}}(k)}{n} \cdot 100\%$$

$f_{\text{kum}}(k)$ = die aufsummierten absoluten Häufigkeiten bis einschließlich zur Kategorie k
 n = Anzahl der Fälle

Kapitel 3 - Mittelwerte und Streuungsmaße

Mittelwert (S. 60)

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}$$

x_i = Messwert des i -ten Falls
 n = Anzahl der Fälle

Mittelwert für eine Häufigkeitstabelle (S. 62)

$$\bar{x} = \frac{\sum_{i=1}^m f_i \cdot k_i}{\sum_{i=1}^m f_i} = \frac{f_1 \cdot k_1 + f_2 \cdot k_2 + f_3 \cdot k_3 + \dots + f_m \cdot k_m}{f_1 + f_2 + f_3 + \dots + f_m}$$

f_i = Die Häufigkeit des Vorkommens einer Kategorie
 k_i = Der Wert einer Kategorie
 m = Die Anzahl der Kategorien

Mittelwert für gruppierte Daten (S. 63)

$$\bar{x} = \frac{\sum_{k=1}^m f_k \cdot x_k}{\sum_{k=1}^m f_k} = \frac{f_1 \cdot x_1 + f_2 \cdot x_2 + f_3 \cdot x_3 + \dots + f_m \cdot x_m}{\sum_{k=1}^m f_k}$$

f_k = Die Häufigkeit des Vorkommens einer Kategorie
 x_k = Die Kategorienmitte
 m = Die Anzahl der Kategorien

Spannweite (S. 65)

$$R = x_{m \max} - x_{m \min}$$

$x_{m \max}$ = höchster Wert einer Verteilung

$x_{m \min}$ = niedrigster Wert einer Verteilung

Interquartilsabstand (S.67)

$$IQR = 3. \text{ Quartil} - 1. \text{ Quartil} = Q_{.75} - Q_{.25}$$

$Q_{.75}$ = obere 25% der Werte einer Verteilung

$Q_{.25}$ = untere 25% der Werte einer Verteilung

Varianz (S.67)

$$\text{var}(x) = s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$$

x_i = Wert eines Falls

\bar{x} = Mittelwert

n = Anzahl der Fälle

Varianz (Inferenzstatistik) (S. 67)

$$\text{var}(x) = s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}$$

x_i = Wert eines Falls

\bar{x} = Mittelwert

n = Anzahl der Fälle

Standardabweichung (S. 68)

$$s = \sqrt{s^2}$$

s^2 = Varianz

Variationskoeffizient (S. 72)

$$V = \frac{s}{\bar{x}}$$

s = Standardabweichung

\bar{x} = Mittelwert

z-Transformation (S. 73)

$$z_i = \frac{x_i - \bar{x}}{s}$$

x_i = einzelner Messwert innerhalb der Vergleichsgruppe

\bar{x} = Mittelwert der Vergleichsgruppe

s = Standardabweichung der Vergleichsgruppe

Kapitel 4 - Kreuztabelle, Chi-Quadrat und Zusammenhangsmaße

Berechnung der erwarteten Häufigkeit (S. 87)

$$f_{e(i,j)} = n_j \cdot p_i$$

n_j = Anzahl der Fälle in Kategorie j

p_i = relative Häufigkeit für die Ausprägung i

oder

$$f_{e(i,j)} = \frac{\text{Zeilensumme } i \cdot \text{Spaltensumme } j}{n}$$

n = Anzahl aller Fälle

Berechnung von Chi-Quadrat bei einer Kreuztabelle (S. 90)

$$\chi^2 = \sum_{i=1}^k \sum_{j=1}^l \frac{(f_{b(i,j)} - f_{e(i,j)})^2}{f_{e(i,j)}}$$

k = Anzahl der Zeilen

f_b = beobachtete Häufigkeiten

f_e = erwartete Häufigkeiten

Freiheitsgrade $df = (k - 1) \cdot (l - 1)$

Phi-Koeffizient (S. 91)

$$\phi = \frac{a \cdot d - b \cdot c}{\sqrt{(a + c) \cdot (b + d) \cdot (a + b) \cdot (c + d)}}$$

a = erste Zelle einer Vier-Felder-Tafel

b = zweite Zelle einer Vier-Felder-Tafel

c = dritte Zelle einer Vier-Felder-Tafel

d = vierte Zelle einer Vier-Felder-Tafel

Beziehung zwischen Phi und Chi-Quadrat (S. 92)

$$\phi = \sqrt{\frac{\chi^2}{n}} \quad \text{bzw.} \quad \chi^2 = n \cdot \phi^2$$

χ^2 = Chi-Quadrat

ϕ = Phi-Koeffizient

n = Anzahl aller Fälle

Kontingenzkoeffizient C (S. 92)

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

χ^2 = Chi-Quadrat

n = Anzahl aller Fälle

Maximale Höhe von $C = C_{\max} = \sqrt{\frac{R-1}{R}}$

R = kleinste Anzahl der Kategorien der Zeilen bzw. Spaltenvariable

Cramers V (S. 93)

$$V = \sqrt{\frac{\chi^2}{n \cdot (R - 1)}}$$

χ^2 = Chi-Quadrat

n = Anzahl aller Fälle

R = kleinste Anzahl der Kategorien der Zeilen bzw. Spaltenvariable

Berechnung von Chi-Quadrat für univariate Verteilungen (S. 94)

$$\chi^2 = \sum_{j=1}^k \frac{(f_{b(j)} - f_{e(j)})^2}{f_{e(j)}}$$

$f_{b(j)}$ = beobachtete Anzahl in Kategorie j

$f_{e(j)}$ = erwartete Anzahl in Kategorie j

k = Anzahl der Kategorien

Kapitel 5 - Wahrscheinlichkeit und Wahrscheinlichkeitsverteilungen

Definition der theoretischen Wahrscheinlichkeit (S. 107)

theoretische Wahrscheinlichkeit (Ereignis A) = $P(A) = \frac{\text{Anzahl der günstigen Ereignisse}}{\text{Anzahl der möglichen Ereignisse}}$

Definition der empirischen Wahrscheinlichkeit (S. 109)

empirische Wahrscheinlichkeit = $\lim_{n \rightarrow \infty} \frac{k}{n}$

k = Anzahl der günstigen Ereignisse

n = Anzahl der durchgeführten Zufallsexperimente

Binomialgleichung (S. 116)

$$P(n; p; k) = \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k} \text{ wobei } \binom{n}{k} = \frac{n!}{k! \cdot (n-k)!}$$

n = Anzahl der durchgeführten Zufallsexperimente

$n!$ = $1 \cdot 2 \cdot 3 \cdot \dots \cdot n$ (gelesen: n Fakultät)

p = Wahrscheinlichkeit des interessierenden Ereignisses beim einmaligen Experiment

k = Anzahl, wie häufig das interessierende Ereignis auftreten soll

Binomialverteilung (S. 118)

Mittelwert der Verteilung (μ) = $n \cdot p$

Standardabweichung der Verteilung (σ) = $n \cdot p \cdot q = n \cdot p \cdot (1-p)$

n = Anzahl der durchgeführten Zufallsexperimente

p = Wahrscheinlichkeit des interessierenden Ereignisses beim einmaligen Experiment

Kapitel 6 - Die Logik des statistischen Schließens

Standardfehler (= Standardabweichung von Stichprobenmittelwerten) (S. 133)

$$\hat{\sigma}_{\bar{x}} = \sqrt{\frac{\sigma^2}{n}}$$

σ^2 = Varianz der Werte in der Stichprobe

n = Anzahl der Fälle

Konfidenzintervall (S. 134)

Untere Grenze = $\mu - z \cdot \hat{\sigma}_{\bar{x}}$

Obere Grenze = $\mu + z \cdot \hat{\sigma}_{\bar{x}}$

μ = Mittelwert der Grundgesamtheit

z = z-Werte der Standardnormalverteilung

$\hat{\sigma}_{\bar{x}}$ = Standardfehler

Kapitel 7 - t-Test: zwei Mittelwerte vergleichen

Berechnung der Prüfgröße t für homogene Varianzen (S. 150)

$$\text{Prüfgröße für homogene Varianzen} = \frac{\bar{x}_1 - \bar{x}_2}{\hat{\sigma}_{(\bar{x}_1 - \bar{x}_2)}}$$

\bar{x}_1 = Mittelwert der Stichprobe 1

\bar{x}_2 = Mittelwert der Stichprobe 2

$\hat{\sigma}_{(\bar{x}_1 - \bar{x}_2)}$ = geschätzter Standardfehler der Mittelwertsdifferenz in der Grundgesamtheit

Freiheitsgrade $df = (n_1 - 1) + (n_2 - 1) = n_1 + n_2 - 2$

n_1 = Anzahl der Fälle in Stichprobe 1

n_2 = Anzahl der Fälle in Stichprobe 2

Berechnung der Prüfgröße t für heterogene Varianzen (S. 152)

$$\text{Prüfgröße t für heterogene Varianzen} = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

\bar{x}_1 = Mittelwert der Stichprobe 1

\bar{x}_2 = Mittelwert der Stichprobe 2

s_1^2 = Varianz der Stichprobe 1

s_2^2 = Varianz der Stichprobe 2

n_1 = Anzahl der Fälle in Stichprobe 1

n_2 = Anzahl der Fälle in Stichprobe 2

Standardfehler der Mittelwertdifferenz (S. 150)

$$\hat{\sigma}_{(\bar{x}_1 - \bar{x}_2)} = \sqrt{\frac{(n_1 - 1) \cdot s_1^2 + (n_2 - 1) \cdot s_2^2}{(n_1 - 1) + (n_2 - 1)}} \cdot \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

n_1 = Anzahl der Fälle in Stichprobe 1 s_1^2 = Varianz der Stichprobe 1
 n_2 = Anzahl der Fälle in Stichprobe 2 s_2^2 = Varianz der Stichprobe 2

Berechnung der Effektstärke einer Mittelwertdifferenz (S. 153-154)

$$\text{Effektstärke einer Mittelwertsdifferenz} = \frac{\bar{x}_1 - \bar{x}_2}{\hat{\sigma}_p}$$

\bar{x}_1 = Mittelwert der Stichprobe 1 als Schätzung für die Grundgesamtheit
 \bar{x}_2 = Mittelwert der Stichprobe 2 als Schätzung für die Grundgesamtheit
 $\hat{\sigma}_p$ = geschätzte Standardabweichung der Grundgesamtheit (Population)

$$\text{Cohens } d = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{s_1^2 + s_2^2}{2}}}$$

\bar{x}_1 = Mittelwert der Stichprobe 1 als Schätzung für die Grundgesamtheit
 \bar{x}_2 = Mittelwert der Stichprobe 2 als Schätzung für die Grundgesamtheit
 s_1 = Standardabweichung der Stichprobe 1
 s_2 = Standardabweichung der Stichprobe 2

Berechnung der Prüfgröße t für abhängige Stichproben (S. 156)

$$\text{Prüfgröße } t \text{ für abhängige Stichproben} = \frac{\bar{x}_D}{\hat{\sigma}_D / \sqrt{n}}$$

\bar{x}_D = Mittelwert der **Differenzen** aller Wertepaare
 $\hat{\sigma}_D$ = geschätzte **Standardabweichung der Mittelwertsdifferenz** in der Grundgesamtheit
 n = Anzahl der Wertepaare

$$\bar{x}_D = \frac{\sum_{i=1}^n x_{D_i}}{n} = \frac{\sum_{i=1}^n (x_{i1} - x_{i2})}{n}$$

x_{D_i} = Differenz der Wertepaare x_{i1} und x_{i2}
 x_{i1} = Wert 1 eines Wertepaares
 x_{i2} = Wert 2 eines Wertepaares
 n = Anzahl der Wertepaare

$$\hat{\sigma}_D = \sqrt{\frac{\sum_{i=1}^n (x_{D_i} - \bar{x}_D)^2}{n - 1}}$$

x_{D_i} = Differenz der Wertepaare x_{i1} und x_{i2}
 \bar{x}_D = Mittelwert der Mittelwertsdifferenzen aller Wertepaare
 n = Anzahl der Wertepaare

Freiheitsgrade $df = n - 1$

Kapitel 8 - Varianzanalyse: mehr als zwei Mittelwerte vergleichen

Gesamtmittelwert (S. 173)

$$\bar{G} = \frac{G}{m \cdot k}$$

m = Anzahl Personen in einer Gruppe
 G = Gesamtsumme aller beobachteten Werte
 k = Anzahl der Faktorstufen

Treatment-Quadratsumme (S. 173)

$$QS_{\text{treat}} = \sum_{j=1}^k m (\bar{A}_j - \bar{G})^2$$

m = Anzahl Personen in einer Gruppe
 \bar{A}_j = Gruppenmittelwert unter der Faktorstufe j
 \bar{G} = Gesamtmittelwert

Treatmentvarianz (S. 173)

$$\hat{\sigma}_{\text{treat}}^2 = \frac{QS_{\text{treat}}}{df}$$

QS_{treat} = Treatment-Quadratsumme
 df = Freiheitsgrade $df = k - 1$

Fehler-Quadratsumme (S. 174)

$$QS_{\text{Fehler}} = \sum_{i=1}^m \sum_{j=1}^k (x_{ij} - \bar{A}_j)^2$$

x_{ij} = Wert der Person i unter der Faktorstufe j
 \bar{A}_j = Gruppenmittelwert unter der Faktorstufe j
 \bar{G} = Gesamtmittelwert

Fehler-Varianz (S. 175)

$$\hat{\sigma}_{\text{Fehler}}^2 = \frac{QS_{\text{Fehler}}}{df}; \text{ Freiheitsgrade } df = k \cdot (m - 1)$$

QS_{Fehler} = Fehler-Quadratsumme

Prüfgröße F (S. 176)

$$F = \frac{\hat{\sigma}_{\text{treat}}^2}{\hat{\sigma}_{\text{Fehler}}^2}$$

$\hat{\sigma}_{\text{treat}}^2$ = Treatmentvarianz
 $\hat{\sigma}_{\text{Fehler}}^2$ = Fehler-Varianz

Effektstärke eta-Quadrat (S. 177)

$$\text{Effektstärke } \eta^2 = \frac{QS_{treat}}{QS_{tot}}$$

QS_{treat} = Treatment-Quadratsumme
 QS_{tot} = totale Quadratsumme

Kapitel 9 - Korrelation: Zusammenhänge identifizieren

Kovarianz (S. 193)

$$\text{cov}(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{n - 1}$$

x_i und y_i = Wert einer Person bei Variable x und bei Variable y
 \bar{x} und \bar{y} = Mittelwerte der Variablen x und y
 n = Anzahl der Untersuchungseinheiten, meistens Personen

Produkt-Moment-Korrelation (= Pearsons r) (S. 194)

$$r = \frac{\text{cov}(x, y)}{s_x \cdot s_y}$$

$\text{cov}(x, y)$ = Kovarianz der Variablen x und y
 s_x und s_y = Standardabweichungen der Variablen x und y

Prüfgröße t für die Moment-Produkt-Korrelation (S. 196)

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

r = ermittelter Korrelationskoeffizient nach Pearson
 n = Anzahl der Untersuchungseinheiten, meist Personen

Spearman's rho (S. 199)

$$r_s = 1 - \frac{6 \cdot \sum_{i=1}^n d_i^2}{n \cdot (n^2 - 1)}$$

d_i^2 = quadrierte Rangplatzdifferenz der i -ten Untersuchungseinheit
 n = Anzahl der Untersuchungseinheiten

Prüfgröße t für Spearman's rho (S. 200)

$$t = \frac{r_s}{\sqrt{(1-r_s^2)/(n-2)}}$$

r_s = Spearman's rho
 n = Anzahl der Untersuchungseinheiten

Kapitel 10 - Skalenbildung

Cronbachs-Alpha (S. 223)

$$\alpha = \frac{k \cdot \bar{r}}{1 + (k - 1) \cdot \bar{r}}$$

k = Anzahl der Items in der Skala
 \bar{r} = durchschnittlicher Korrelationskoeffizient der Items (auch als Homogenität bezeichnet)

Kapitel 11 - Regression: komplexe Zusammenhänge analysieren und Vorhersagen treffen

Steigung der Regressionsgeraden (S. 235)

$$b_1 = \frac{\text{cov}(x, y)}{s_x^2}$$

$\text{cov}(x, y)$ = Kovarianz der beiden Variablen x und y
 s_x^2 = Varianz der Variablen x

Achsenabschnitt der Regressionsgeraden (S. 236)

$$b_0 = \bar{y} - b_1 \cdot \bar{x}$$

\bar{y} = Mittelwert der Variable y
 b_1 = Steigung der Regressionsgerade
 \bar{x} = Mittelwert der Variable x

Standardisierter Regressionskoeffizient (S. 236)

$$\beta_1 = b_1 \cdot \frac{s_x}{s_y}$$

b_1 = unstandardisierter Regressionskoeffizient
 $s_{x/y}$ = Standardabweichung der Variablen x/y

Bestimmtheitsmaß R-Quadrat (S. 237)

$$R^2 = \frac{s_{\hat{y}}^2}{s_y^2}$$

$s_{\hat{y}}^2$ = Varianz der vorhergesagten Werte
 s_y^2 = Varianz der beobachteten Werte

Korrigiertes R-Quadrat (S. 242)

$$R_{adj}^2 = 1 - \frac{n-1}{n-p-1} \cdot (1 - R^2)$$

n = Anzahl der Fälle
 p = Anzahl der Prädiktoren
 R^2 = unkorrigiertes Bestimmtheitsmaß R^2