

Inhaltsverzeichnis

1	Wahrscheinlichkeitstheorie.....	3
1.1	Wahrscheinlichkeitsbegriffe.....	3
1.2	Bedingte Wahrscheinlichkeit.....	3
1.3	Satz von Bayes.....	3
1.4	Stochastische Unabhängigkeit zweier Ereignisse.....	3
1.5	Axiome der Wahrscheinlichkeitsrechnung von Kolmogoroff.....	3
1.6	Verteilungsfunktion einer Zufallsvariable (ZV) X.....	3
1.7	Dichte einer diskreten Zufallsvariable (Wahrscheinlichkeitsfunktion).....	3
1.8	Zusammenhänge von Dichten und Verteilungsfunktionen.....	3
1.9	Eigenschaften der Dichtefunktion.....	4
1.10	Unabhängigkeit zweier Zufallsgrößen.....	4
1.11	Erwartungswert μ , Varianz und Standardabweichung.....	4
1.12	Rechenregeln von i.i.d. Zufallsgrößen.....	5
1.13	Standardisierung von Zufallsvariablen.....	5
1.14	Verteilungen.....	5
1.15	Grenzwertsätze.....	6
2	Datendarstellung.....	7
2.1	Lagemaßzahlen.....	7
2.2	Besondere Lagemaßzahlen: Quantile.....	7
2.3	Streuungsmaßzahlen.....	8
3	Mehrdimensionale Merkmale.....	9
3.1	Zusammenhangsmaße.....	9
3.2	Regression.....	10
3.3	Kontingenz.....	11
3.4	Assoziationsmaße.....	12
4	Inferenzstatistik.....	13
4.1	Schätzfunktionen.....	13
4.2	Konfidenzintervalle.....	14
4.3	Statistische Testverfahren.....	17

1 Wahrscheinlichkeitstheorie

1.1 Wahrscheinlichkeitsbegriffe

Wahrscheinlichkeit nach Laplace: $\frac{\text{Anzahl der günstigen Fälle}}{\text{Anzahl der (gleich) möglichen Fälle}}$

Wahrscheinlichkeit nach Mises: $P(A) = \lim_{n \rightarrow \infty} \frac{n_A}{n}$ n_A : Anzahl der Erfolge
 n : Anzahl der Versuche

1.2 Bedingte Wahrscheinlichkeit

$$P(B|A) := \frac{P(B \cap A)}{P(A)} = \frac{P(A \cap B)}{P(A)} ; P(A|B) := \frac{P(A \cap B)}{P(B)} = \frac{P(B \cap A)}{P(B)}$$

1.3 Satz von Bayes

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{P(A) \cdot P(B|A)}{P(B|A) \cdot P(A) + P(B|A^c) \cdot P(A^c)} = \frac{P(B|A) \cdot P(A)}{P(B|A) \cdot P(A) + P(B|A^c) \cdot P(A^c)}$$

1.4 Stochastische Unabhängigkeit zweier Ereignisse

1. $P(B|A) = P(B)$ und $P(A|B) = P(A)$
2. $P(A \cap B) = P(A) \cdot P(B)$

1.5 Axiome der Wahrscheinlichkeitsrechnung von Kolmogoroff

$P(A) \geq 0$ für alle Ereignisse
 $P(A \cup B) = P(A) + P(B)$ für disjunkte Ereignisse
 $P(\Omega) = 1$

1.6 Verteilungsfunktion einer Zufallsvariable (ZV) X

$$F(x) = P(X \leq x)$$

1.7 Dichte einer diskreten Zufallsvariable (Wahrscheinlichkeitsfunktion)

$$f(x) = P(X = x)$$

1.8 Zusammenhänge von Dichten und Verteilungsfunktionen

Handelt es sich um eine stetige Zufallsgröße, so gilt allgemein:

$$F(b) = P(-\infty \leq X \leq b) = \int_{-\infty}^b f_x(x) dx$$

Es gilt:

$$P(a < X \leq b) = \sum_{a < x_i \leq b} f(x_i) \quad \text{bei diskreter Zufallsvariable } X$$

$$P(a \leq X \leq b) = \int_a^b f_x(x) dx = F(b) - F(a) \quad \text{bei stetiger Zufallsvariable } X$$

$$P(X = x) = 0 \quad \text{für alle } x \in \mathbb{R}, \text{ falls } X \text{ eine stetige ZV ist}$$
$$F'(x) = f(x)$$

1.9 Eigenschaften der Dichtefunktion

$$f(x) \geq 0$$

$$\int_{-\infty}^{\infty} f(x) dx = 1$$

1.10 Unabhängigkeit zweier Zufallsgrößen

Zwei Zufallsgrößen X und Y heißen unabhängig, falls die Ereignisse $X \leq x_0$ und $Y \leq y_0$ für beliebige Werte von x_0 und y_0 unabhängig sind. Es gilt dann:

$$P(X = x_0 \text{ und } Y = y_0) = P(X = x_0) \cdot P(Y = y_0)$$

$$P(X \leq x_0 \text{ und } Y \leq y_0) = P(X \leq x_0) \cdot P(Y \leq y_0)$$

1.11 Erwartungswert μ , Varianz und Standardabweichung

Erwartungswert [E(X)]

$$E(X) = \sum_{i=1}^n x_i P(X = x_i) \quad \text{bei diskreter Zufallsvariable } X$$

$$E(X) = \int_{-\infty}^{\infty} x f(x) dx \quad \text{bei stetiger Zufallsvariable } X$$

Varianz [Var(X) oder σ^2]

$$Var(X) = \sum_{i=1}^n (x_i - E(X))^2 P(X = x_i) \quad \text{bei diskreter Zufallsvariable } X$$

$$Var(X) = \int_{-\infty}^{\infty} (x - E(X))^2 f(x) dx \quad \text{bei stetiger Zufallsvariable } X$$

$$\text{Standardabweichung: } \sigma = \sqrt{Var(X)}$$

1.12 Rechenregeln von i.i.d. Zufallsgrößen

Ist $E(X_i) = \mu$ und $\text{Var}(X_i) = \sigma^2$, so gilt:

$$\begin{aligned}
 E(X_1 + X_2 + \dots + X_n) &= E(X_1) + E(X_2) + \dots + E(X_n) &&= n\mu \\
 \text{Var}(X_1 + X_2 + \dots + X_n) &= \text{Var}(X_1) + \text{Var}(X_2) + \dots + \text{Var}(X_n) &&= n\sigma^2 \\
 E\left(\frac{1}{n}(X_1 + X_2 + \dots + X_n)\right) &= E(\bar{X}) = \frac{1}{n} E(X_1 + X_2 + \dots + X_n) = \frac{1}{n} n\mu &&= \mu \\
 \text{Var}\left(\frac{1}{n}(X_1 + X_2 + \dots + X_n)\right) &= \text{Var}(\bar{X}) = \left(\frac{1}{n}\right)^2 \cdot \text{Var}(X_1 + X_2 + \dots + X_n) = \frac{1}{n^2} \cdot n\sigma^2 &&= \frac{\sigma^2}{n}
 \end{aligned}$$

1.13 Standardisierung von Zufallsvariablen

Lineare Transformation der Normalverteilung in Standardnormalverteilung.

Wenn $X \sim N(\mu; \sigma^2)$, dann gilt für die Zufallsgröße Z mit:

$$Z = \frac{X - \mu}{\sigma} \sim N(0; 1)$$

1.14 Verteilungen

Verteilung			E(X)	Var(X)
Bernoulli-Verteilung $X \sim \text{Be}(p)$	$P(X = 1) = p$ $P(X = 0) = 1 - p$		p	$p \cdot (1 - p)$
Binomial-Verteilung $X \sim B(n; p)$	$f(x) = \binom{n}{x} \cdot p^x \cdot q^{n-x}$		np	$np(1 - p)$
Stetige Gleichverteilung $X \sim G([a; b])$	$f(x) = \begin{cases} \frac{1}{b-a} & \text{für } a \leq x \leq b \\ 0 & \text{sonst} \end{cases}$	$F(x) = \begin{cases} 0 & \text{für } x \leq a \\ \frac{1}{b-a} \cdot (x - a) & \text{für } a \leq x \leq b \\ 1 & \text{für } x \geq b \end{cases}$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$
Normal-Verteilung $X \sim N(\mu; \sigma^2)$	$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-0,5\left(\frac{x-\mu}{\sigma}\right)^2}$	$F(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot \int_a^b e^{-0,5\left(\frac{x-\mu}{\sigma}\right)^2} dx$	μ	σ^2
χ^2 -Verteilung $Y \sim \chi^2(n)$		$Y = \sum_{i=1}^n X_i^2$	$E(Y) = n$	$\text{Var}(Y) = 2n$

1.15 Grenzwertsätze

Gesetz der großen Zahl

$$\lim_{n \rightarrow \infty} P(|\bar{X} - \mu| \leq \varepsilon) = 1 \quad \forall \varepsilon > 0 \quad ; \quad \lim_{n \rightarrow \infty} P(|R - p| \leq \varepsilon) = 1 \quad \forall \varepsilon > 0$$

Zentraler Grenzwertsatz

$$n \rightarrow \infty: \quad \bar{X} \overset{as}{\sim} N\left(\mu; \frac{\sigma^2}{n}\right) \quad ; \quad n \rightarrow \infty: \quad R \overset{as}{\sim} N\left(p; \frac{p(1-p)}{n}\right)$$

Standardisierung

Wenn $X \sim N(\mu; \sigma^2)$ -verteilt ist, dann ist $Z=(X-\mu)/\sigma \sim N(0,1)$ -verteilt.

$$\text{Wenn } \bar{X} \overset{as}{\sim} N\left(\mu; \frac{\sigma^2}{n}\right), \text{ dann gilt: } \frac{\bar{X} - \mu}{\sigma} \cdot \sqrt{n} \overset{as}{\sim} N(0; 1)$$

bzw.

$$\text{Wenn } \bar{X} \sim N\left(\mu; \frac{\sigma^2}{n}\right), \text{ dann gilt: } \frac{\bar{X} - \mu}{\sigma} \cdot \sqrt{n} \sim N(0; 1)$$

2 Datendarstellung

2.1 Lagemaßzahlen

Modus

x_{mod} : Ausprägung mit der größten Häufigkeit

Median

Seien $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$ der Größe nach geordnete Messwerte, so liegt der Median „in der Mitte“ dieser Zahlen. Genauer gilt:

$$x_{med} := \begin{cases} x_{(\frac{n+1}{2})} & \text{für } n \text{ ungerade} \\ \frac{1}{2} (x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}) & \text{für } n \text{ gerade} \end{cases}$$

Arithmetisches Mittel

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \text{ für einzelne Werte}$$

$$\bar{x} = \frac{1}{n} (\sum_{j=1}^k n_j \cdot x_j) \text{ für } k \text{ unterschiedliche Ausprägungen}$$

$$\bar{x} = \frac{1}{n} (\sum_{j=1}^k n_j \cdot m_j) \text{ für gruppierte Werte}$$

(Bei Klassenbildung/Gruppenbildung: m_j als Klassenmitte der Klasse j bzw. evtl. der sinnvoll geschlossenen Klasse j)

Geometrisches Mittel

$$\bar{x}_G = \sqrt[n]{\prod_{i=1}^n x_i}$$

2.2 Besondere Lagemaßzahlen: Quantile

Gegeben seien die n Daten x_1, x_2, \dots, x_n in aufsteigender Ordnung: $x^{(1)}, x^{(2)}, \dots, x^{(n)}$

$$\tilde{x}_p := \begin{cases} x^{(i)}, \text{ falls } np \text{ nicht ganzzahlig mit der kleinsten ganzen Zahl } i > np \\ \frac{1}{2} (x^{(np)} + x^{(np+1)}), \text{ falls } np \text{ ganzzahlig} \end{cases}$$

2.3 Streuungsmaßzahlen

Spannweite (Range)

$$R = x_{max} - x_{min} = x_{(n)} - x_{(1)}$$

Quartilsabstand

$$d_Q = \tilde{x}_{0,75} - \tilde{x}_{0,25}$$

Mittlere Abweichung

$$DAA_a = \frac{1}{n} \sum_{i=1}^n |x_i - a|$$

Empirische Varianz S^2 und Standardabweichung S

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

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

Variationskoeffizient (nur für positive Merkmale sinnvoll anwendbar)

$$v = \frac{S}{\bar{x}}$$

3 Mehrdimensionale Merkmale

3.1 Zusammenhangsmaße

Kovarianz S_{XY}

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

Korrelationskoeffizient nach Pearson (Voraussetzung: X und Y sind metrische Merkmale)

$$r_{XY} = \frac{s_{XY}}{s_X s_Y} = \frac{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

X und Y heißen ...

... positiv korreliert, wenn $r_{XY} > 0$

... unkorreliert, wenn $r_{XY} = 0$

... negativ korreliert, wenn $r_{XY} < 0$

Liegen alle Punkte auf einer Geraden, dann gilt $|r_{XY}| = 1$

Rangkorrelationskoeffizient nach Spearman

$$r_{XY}^S = r_{UV} = \frac{s_{UV}}{\sqrt{s_U^2 \cdot s_V^2}} = \frac{s_{UV}}{s_U \cdot s_V}$$

mit $U = R(X)$ und $V = R(Y)$

3.2 Regression

Annahme: $y_i = \alpha + \beta x_i + \varepsilon_i$ mit α, β Modellparameter
 ε Störterm, Zufallsvariable

Geschätzte y_i : $\hat{y}_i = a + bx_i$

Residuen: $e_i = y_i - \hat{y}_i$

Kleinst-Quadrate-Bedingung

$$Q(a; b) = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - a - bx_i)^2 \rightarrow \min$$

Kleinst-Quadrate-Schätzer (KQ-Methode)

$$a = \bar{y} - b\bar{x} \quad \text{und} \quad b = \frac{s_{XY}}{s_x^2}$$

Streuungszerlegung

$$S_Y^2 = S_{\hat{Y}}^2 + S_e^2 \quad \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n-1} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \frac{1}{n-1} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Bestimmtheitsmaß (Anteil der durch das lineare Modell erklärten Varianz) der Regression von Y bzgl. X

$$B = r^2 = \frac{S_{\hat{Y}}^2}{S_Y^2} = r_{XY}^2$$

Geschätzte Standardabweichung

$$s_e = \sqrt{\frac{1}{n-2} \sum_{i=1}^n e_i^2}$$

Partielle Regression

Gegeben seien die Merkmale X, Y und Z mit den unten stehenden Regressionsgleichungen. ε und F sind dabei die Residuen der Regressionen von X auf Z bzw. von Y auf Z.

$$X = \hat{X} + \varepsilon = a + bZ + \varepsilon \quad Y = \hat{Y} + F = c + dZ + F$$

Partieller Korrelationskoeffizient (Korrelation von X und Y bei gegebenem Z)

$$r_{XY|Z} = \frac{r_{XY} - r_{XZ} \cdot r_{YZ}}{\sqrt{1 - r_{XZ}^2} \cdot \sqrt{1 - r_{YZ}^2}}$$

3.3 Kontingenz

Häufigkeiten und Häufigkeitsverteilungen

n : Gesamtzahl der Untersuchungseinheiten

n_{ij} : Häufigkeit der Merkmalskombination (A_i, B_j)

$n_{i\cdot}$: Häufigkeit von Merkmal A_i

$n_{\cdot j}$: Häufigkeit von Merkmal B_j

$f_{ij} = \frac{n_{ij}}{n}$: Relative Häufigkeit der Merkmalskombination (A_i, B_j)

$f_{i\cdot} = \frac{n_{i\cdot}}{n}$: Relative Häufigkeit von Merkmal A_i

$f_{\cdot j} = \frac{n_{\cdot j}}{n}$: Relative Häufigkeit von Merkmal B_j

Bedingte relative Häufigkeiten

$f(B_j/A_i) := \frac{n_{ij}}{n_{i\cdot}}$ $f(A_i/B_j) := \frac{n_{ij}}{n_{\cdot j}}$

Bedingte Verteilungen

Bedingte Verteilung von $Y/X = B_j$

Bedingte Verteilung von $X/Y = A_i$

Unabhängigkeit von Merkmalen

$\frac{n_{ij}}{n_{i\cdot}} = \frac{n_{\cdot j}}{n} \iff \frac{n_{ij}}{n_{\cdot j}} = \frac{n_{i\cdot}}{n} \iff n_{ij} = \frac{n_{i\cdot} \cdot n_{\cdot j}}{n} \iff \frac{n_{ij}}{n} = \frac{n_{i\cdot}}{n} \cdot \frac{n_{\cdot j}}{n} \quad \forall i \text{ und } j$

3.4 Assoziationsmaße

Quadratische Kontingenz χ^2

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^s \frac{(n_{ij} - e_{ij})^2}{e_{ij}} \quad \text{Wertebereich: } 0 \leq \chi^2 \leq n \cdot \min(r-1, s-1)$$

Mittlere quadratische Kontingenz ϕ^2

$$\phi^2 = \frac{\chi^2}{n} \quad \text{Wertebereich: } 0 \leq \chi^2 \leq \min(r-1, s-1)$$

ϕ -Koeffizient

$$\phi = \sqrt{\frac{\chi^2}{n}} \quad \text{Wertebereich: } 0 \leq \phi \leq \min(\sqrt{r-1}, \sqrt{s-1})$$

Kontingenzmaß nach Tschuprov

$$T = \sqrt{\frac{\chi^2}{n \cdot \sqrt{(r-1)(s-1)}}$$

Kontingenzmaß nach Cramér

$$V = \sqrt{\frac{\chi^2}{n \cdot \min(r-1, s-1)}} \quad \text{Wertebereich: } 0 \leq V \leq 1$$

Kontingenzkoeffizient von Pearson C

$$C = \sqrt{\frac{\chi^2}{\chi^2 + n}} \quad \text{Wertebereich: } 0 \leq C \leq \sqrt{\frac{\min(r,s)-2}{\min(r,s)-1}}$$

Normierter Kontingenzkoeffizient C_{Corr}

$$C_{Corr} = \sqrt{\frac{\min(r,s)-1}{\min(r,s)-2} \cdot \frac{\chi^2}{\chi^2 + n}} \quad \text{Wertebereich: } 0 \leq C_{Corr} \leq 1$$

4 Inferenzstatistik

4.1 Schätzfunktionen

(a) für den Mittelwert μ :

\bar{X} als Schätzer für den Mittelwert

$$E(\bar{X}) = E\left[\frac{1}{n}(X_1 + X_2 + \dots + X_n)\right] = \mu$$

$$Var(\bar{X}) = Var\left[\frac{1}{n}(X_1 + X_2 + \dots + X_n)\right] = \frac{\sigma^2}{n}$$

$$STE(\bar{X}) = \sqrt{Var(\bar{X})}$$

(b) für den Anteilswert p :

R als Schätzer für den Anteilswert.

Es gilt $P(X_i = 1) = p$ und $P(X_i = 0) = 1-p$ mit X_1, X_2, \dots, X_n i.i.d.

$$E(X) = p$$

$$Var(X) = p(1 - p)$$

$$R = \frac{1}{n}(X_1 + X_2 + \dots + X_n) = \bar{X}$$

für $np(1 - p) > 9$ ist $R \stackrel{as}{\sim} N\left(p; \frac{p(1-p)}{n}\right)$

4.2 Konfidenzintervalle

Standardisierung und $\frac{1+\gamma}{2}$ -Quantil der Standardnormalverteilung

Konfidenzintervall für den Mittelwert μ bei Normalverteilung und bekannter σ^2

Annahme: X ist normalverteilt und es gilt $\bar{X} \sim N\left(\mu; \frac{\sigma^2}{n}\right)$

$$Z = \frac{\bar{X} - \mu}{\sigma} \cdot \sqrt{n} \sim N(0; 1)$$

$$P\left(\frac{z_{1-\gamma}}{2} \leq Z \leq \frac{z_{1+\gamma}}{2}\right) = P\left(-\frac{z_{1+\gamma}}{2} \leq Z \leq \frac{z_{1+\gamma}}{2}\right) = \gamma$$

Es ergibt sich: $P\left(\bar{X} - \frac{z_{1+\gamma}}{2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + \frac{z_{1+\gamma}}{2} \frac{\sigma}{\sqrt{n}}\right) = \gamma$

Konfidenzintervall für μ zum Sicherheitsniveau γ : $\left[\bar{X} - \frac{z_{1+\gamma}}{2} \frac{\sigma}{\sqrt{n}}; \bar{X} + \frac{z_{1+\gamma}}{2} \frac{\sigma}{\sqrt{n}}\right]$

mit $\frac{z_{1+\gamma}}{2}$ ist das $\frac{1+\gamma}{2}$ -Quantil der Standardnormalverteilung

Konfidenzintervall für den Mittelwert μ bei Normalverteilung und unbekannter Varianz σ^2 sowie kleiner Stichprobe

Annahme: X ist normalverteilt

Dann ist die Zufallsgröße $T = \frac{\bar{X} - \mu}{S} \cdot \sqrt{n}$ t-verteilt mit n-1 Freiheitsgraden

Konfidenzintervall für μ zum Sicherheitsniveau γ lautet: $\left[\bar{X} - t_{(n-1; \frac{1+\gamma}{2})} \frac{S}{\sqrt{n}}; \bar{X} + t_{(n-1; \frac{1+\gamma}{2})} \frac{S}{\sqrt{n}}\right]$

mit $t_{(n-1; \frac{1+\gamma}{2})}$ als $\frac{1+\gamma}{2}$ -Quantil der t-Verteilung mit n-1 Freiheitsgraden

Konfidenzintervall für den Mittelwert μ bei Normalverteilung und unbekannter Varianz σ^2 sowie großer Stichprobe

Annahme: X ist normalverteilt und n groß (Faustregel: $n \geq 30$)

Dann ist die Zufallsgröße $Z = \frac{\bar{X} - \mu}{S} \cdot \sqrt{n}$ approximativ standardnormalverteilt.

Konfidenzintervall für μ zum Sicherheitsniveau γ lautet: $\left[\bar{X} - \frac{z_{1+\gamma}}{2} \frac{S}{\sqrt{n}}; \bar{X} + \frac{z_{1+\gamma}}{2} \frac{S}{\sqrt{n}}\right]$

mit $\frac{z_{1+\gamma}}{2}$ ist das $\frac{1+\gamma}{2}$ -Quantil der Standardnormalverteilung

Approximatives Konfidenzintervall für den Anteilswert p bei hinreichend großem Stichprobenumfang (Faustregel: $n \geq 30$)

$$\left[R - z_{\frac{1+\gamma}{2}} \cdot \sqrt{\frac{R \cdot (1-R)}{n}} ; R + z_{\frac{1+\gamma}{2}} \cdot \sqrt{\frac{R \cdot (1-R)}{n}} \right]$$

mit $z_{\frac{1+\gamma}{2}}$ ist das $\frac{1+\gamma}{2}$ -Quantil der Standardnormalverteilung

Approximatives Konfidenzintervall für die Erwartungswertdifferenz ($\mu_X - \mu_Y$) bei i.i.d. Stichproben, unbekanntem Varianzen und jeweils hinreichend großen Stichprobenumfängen (Faustregel: $m \geq 30$ und $n \geq 30$)

Es gilt: $Var(\bar{X} - \bar{Y}) = Var(\bar{X}) + Var(\bar{Y}) = \frac{\sigma_X^2}{m} + \frac{\sigma_Y^2}{n}$

Schätzung der Varianz: $Var(\bar{X} - \bar{Y}) = \frac{S_X^2}{m} + \frac{S_Y^2}{n}$

$$\left[(\bar{X} - \bar{Y}) - z_{\frac{1+\gamma}{2}} \cdot S_d ; (\bar{X} - \bar{Y}) + z_{\frac{1+\gamma}{2}} \cdot S_d \right]$$

$$\text{mit } S_d = \sqrt{\frac{S_X^2}{m} + \frac{S_Y^2}{n}}$$

mit $z_{\frac{1+\gamma}{2}}$ ist das $\frac{1+\gamma}{2}$ -Quantil der Standardnormalverteilung

Konfidenzintervall für die Erwartungswertdifferenz ($\mu_X - \mu_Y$) bei i.i.d. Stichproben, unbekanntem, aber gleichen Varianzen ($\sigma_X^2 = \sigma_Y^2 = \sigma^2$) und Normalverteilungsannahme

Es gilt: $Var(\bar{X} - \bar{Y}) = Var(\bar{X}) + Var(\bar{Y}) = \frac{\sigma^2}{m} + \frac{\sigma^2}{n} = \sigma^2 \cdot \left(\frac{1}{m} + \frac{1}{n} \right)$

Erwartungstreuer Punktschätzer für σ^2 : $S_{X,Y}^2 = \frac{1}{m+n-2} \cdot \left[\sum_{i=1}^m (X_i - \bar{X})^2 + \sum_{j=1}^n (Y_j - \bar{Y})^2 \right]$

Dann gilt für $U = \frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{S_{X,Y} \cdot \sqrt{\frac{1}{m} + \frac{1}{n}}} \sim t(m+n-2)$

Das Konfidenzintervall für $\mu_X - \mu_Y$ zum Sicherheitsniveau γ lautet damit:

$$\left[(\bar{X} - \bar{Y}) - t_{(m+n-2; \frac{1+\gamma}{2})} \cdot S_{X,Y} \cdot \sqrt{\frac{1}{m} + \frac{1}{n}} ; (\bar{X} - \bar{Y}) + t_{(m+n-2; \frac{1+\gamma}{2})} \cdot S_{X,Y} \cdot \sqrt{\frac{1}{m} + \frac{1}{n}} \right]$$

mit $t_{(m+n-2; \frac{1+\gamma}{2})}$ ist das $\frac{1+\gamma}{2}$ -Quantil der t-Verteilung mit $m+n-2$ Freiheitsgraden

Approximatives Konfidenzintervall für die Anteilswertdifferenz bei zwei voneinander stochastisch unabhängigen i.i.d.-Stichproben für $(p_X - p_Y)$ und jeweils hinreichend großen Stichprobenumfängen (Faustregel: $m \geq 30$ und $n \geq 30$) für das Sicherheitsniveau γ

$$[(R_X - R_Y) - \frac{z_{1+\gamma}}{2} \cdot S_d ; (R_X - R_Y) + \frac{z_{1+\gamma}}{2} \cdot S_d]$$

$$\text{mit } S_d = \sqrt{\frac{R_X \cdot (1-R_X)}{m} + \frac{R_Y \cdot (1-R_Y)}{n}}$$

und mit $\frac{z_{1+\gamma}}{2}$ ist das $\frac{1+\gamma}{2}$ -Quantil der Standardnormalverteilung

Konfidenzintervall für die Erwartungswertdifferenz ($\mu_W = \mu_X - \mu_Y$) bei hinreichend großem Stichprobenumfang (Faustregel: $n \geq 30$) und bei verbundenen Stichproben für das Sicherheitsniveau γ

$$[\bar{W} - \frac{z_{1+\gamma}}{2} \cdot \frac{S_W}{\sqrt{n}} ; \bar{W} + \frac{z_{1+\gamma}}{2} \cdot \frac{S_W}{\sqrt{n}}]$$

$$\text{mit } W_i = X_i - Y_i \text{ und } S_W^2 = \frac{1}{n-1} \sum_{i=1}^n (W_i - \bar{W})^2$$

und mit $\frac{z_{1+\gamma}}{2}$ ist das $\frac{1+\gamma}{2}$ -Quantil der Standardnormalverteilung

4.3 Statistische Testverfahren

Einseitiger approximativer Test auf den Anteilswert p zum Signifikanzniveau α

Als Faustregel muss gelten: $n \cdot p_0 \cdot (1 - p_0) > 9$

$$H_0: p \leq p_0$$

$$H_1: p > p_0$$

$$\text{Ablehnungsbereich: } \left[p_0 + z_{1-\alpha} \cdot \sqrt{\frac{p_0(1-p_0)}{n}} ; 1 \right]$$

$$H_0: p \geq p_0$$

$$H_1: p < p_0$$

$$\text{Ablehnungsbereich: } \left[0 ; p_0 - z_{1-\alpha} \cdot \sqrt{\frac{p_0(1-p_0)}{n}} \right]$$

mit $z_{1-\alpha}$ ist das $1 - \alpha$ -Quantil der Standardnormalverteilung

Zweiseitiger approximativer Test auf den Anteilswert p zum Signifikanzniveau α

Als Faustregel muss gelten: $n \cdot p_0 \cdot (1 - p_0) > 9$

$$H_0: p = p_0$$

$$H_1: p \neq p_0$$

$$\text{Annahme- oder Nichtablehnungsbereich: } \left[p_0 - z_{1-\frac{\alpha}{2}} \cdot \sqrt{\frac{p_0(1-p_0)}{n}} ; p_0 + z_{1-\frac{\alpha}{2}} \cdot \sqrt{\frac{p_0(1-p_0)}{n}} \right]$$

mit $z_{1-\frac{\alpha}{2}}$ ist das $1 - \frac{\alpha}{2}$ -Quantil der Standardnormalverteilung

(Zweiseitiger) Test auf Erwartungswert (t-Test / Gauß-Test) zum Signifikanzniveau α

$$H_0: \mu = \mu_0$$

$$H_1: \mu \neq \mu_0$$

$$\text{Testgröße } T = \frac{\bar{X} - \mu_0}{s} \cdot \sqrt{n}$$

H_0 wird abgelehnt, falls $|T| > t(n-1; 1 - \frac{\alpha}{2})$

mit $t(n-1; 1 - \frac{\alpha}{2})$ ist das $1 - \frac{\alpha}{2}$ -Quantil der t-Verteilung mit n-1 Freiheitsgraden oder alternativ mit Testgröße \bar{X}

H_0 wird beibehalten, falls $\bar{X} \in \left[\mu_0 - t\left(n-1; 1 - \frac{\alpha}{2}\right) \cdot \frac{s}{\sqrt{n}} ; \mu_0 + t\left(n-1; 1 - \frac{\alpha}{2}\right) \cdot \frac{s}{\sqrt{n}} \right]$

Zu beachten:

Für $n \leq 30$ ist der Test nur gültig, wenn $X \sim N(\mu; \sigma^2)$

Für $n > 30$ (und Verteilung, die nicht zu Ausreißern neigt) darf das $1 - \frac{\alpha}{2}$ -Quantil der t-Verteilung mit n-1 Freiheitsgraden durch $z_{1 - \frac{\alpha}{2}}$, also das $1 - \frac{\alpha}{2}$ -Quantil der

Standardnormalverteilung, ersetzt werden

(Einseitiger) Test auf Erwartungswert (t-Test / Gauß-Test) zum Signifikanzniveau α

$$H_0: \mu \leq \mu_0$$

$$H_1: \mu > \mu_0$$

$$\text{Testgröße } T = \frac{\bar{X} - \mu_0}{s} \cdot \sqrt{n}$$

H_0 wird abgelehnt, falls $T > t(n-1; 1 - \alpha)$

mit $t(n-1; 1 - \alpha)$ ist das $1 - \alpha$ -Quantil der t-Verteilung mit n-1 Freiheitsgraden oder alternativ mit Testgröße \bar{X}

H_0 wird abgelehnt, falls $\bar{X} \in \left[\mu_0 + t(n-1; 1 - \alpha) \cdot \frac{s}{\sqrt{n}} ; \infty \right)$

$$H_0: \mu \geq \mu_0$$

$$H_1: \mu < \mu_0$$

$$\text{Testgröße } T = \frac{\bar{X} - \mu_0}{s} \cdot \sqrt{n}$$

H_0 wird abgelehnt, falls $T < -t(n-1; 1 - \alpha)$

mit $t(n-1; 1 - \alpha)$ ist das $1 - \alpha$ -Quantil der t-Verteilung mit n-1 Freiheitsgraden oder alternativ mit Testgröße \bar{X}

H_0 wird abgelehnt, falls $\bar{X} \in \left(-\infty ; \mu_0 - t(n-1; 1 - \alpha) \cdot \frac{s}{\sqrt{n}} \right]$

Zu beachten:

Für $n \leq 30$ ist der Test nur gültig, wenn $X \sim N(\mu; \sigma^2)$

Für $n > 30$ (und Verteilung, die nicht zu Ausreißern neigt) darf das $1 - \alpha$ -Quantil der t-Verteilung mit n-1 Freiheitsgraden durch $z_{1 - \alpha}$, also das $1 - \alpha$ -Quantil der Standardnormalverteilung, ersetzt werden

Zweiseitiger doppelter t-Test auf Erwartungswertdifferenz zum Signifikanzniveau α

Voraussetzung: zwei unabhängige Stichproben, normalverteilte Zufallsgrößen X und Y, Varianzen gleich (aber unbekannt)

$$H_0: \mu_x - \mu_y = d_0 \quad (d_0 = 0 \text{ entspricht } \mu_x = \mu_y)$$
$$H_1: \mu_x - \mu_y \neq d_0 \quad (d_0 \neq 0 \text{ entspricht } \mu_x \neq \mu_y)$$

Annahme- bzw. Nichtablehnungsbereich:

$$[d_0 - t_{(m+n-2; 1-\frac{\alpha}{2})} \cdot S_d ; d_0 + t_{(m+n-2; 1-\frac{\alpha}{2})} \cdot S_d]$$

mit $S_d = S_{X,Y} \cdot \sqrt{\frac{1}{m} + \frac{1}{n}}$ und $S_{X,Y} = \frac{1}{m+n-2} [\sum_{i=1}^m (x_i - \bar{x})^2 + \sum_{j=1}^n (y_j - \bar{y})^2]$

χ^2 -Unabhängigkeitstest zum Signifikanzniveau α

Dieser Test prüft die Hypothese, ob zwei kategoriale Merkmale stochastisch unabhängig sind oder nicht.

$$H_0: p_{ij} = p_{i \cdot} \cdot p_{\cdot j}$$
$$H_1: p_{ij} \neq p_{i \cdot} \cdot p_{\cdot j}$$

Teststatistik: χ^2

$$\chi^2 = \sum_{i=1}^k \sum_{j=1}^l \frac{(n_{ij} - e_{ij})^2}{e_{ij}} \quad \text{mit } e_{ij} = \frac{n_{i \cdot} \cdot n_{\cdot j}}{n}$$

Faustregel: alle $n_{ij} \geq 5$

H_0 wird abgelehnt, falls χ^2 größer dem $(1-\alpha)$ -Quantil der χ^2 -Verteilung mit $(k-1) \cdot (l-1)$ Freiheitsgraden.