

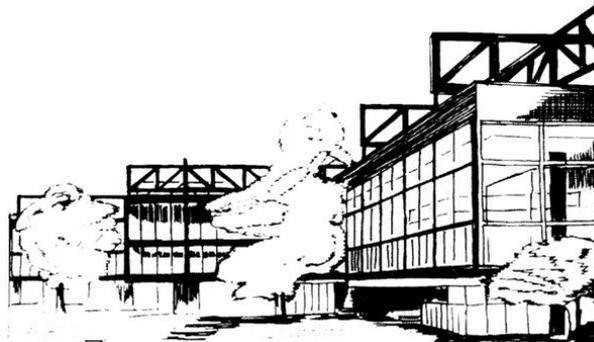


HELMUT SCHMIDT  
UNIVERSITÄT  
Universität der Bundeswehr Hamburg

FÄCHERGRUPPE MATHEMATIK/STATISTIK

# Formelsammlung Stochastik bzw. Statistik

**Beschreibende Statistik**  
**Wahrscheinlichkeitsrechnung**  
**Schließende Statistik**



© Christian Hassold, Sven Knoth, Miriam Seifert, Detlef Steuer  
5. Februar 2020

# Inhaltsverzeichnis

<b>1 Beschreibende Statistik</b>	<b>4</b>
1.1 Grundbegriffe . . . . .	4
1.2 Maßzahlen . . . . .	7
1.2.1 Lagemaße . . . . .	7
1.2.2 Streuungsmaße . . . . .	8
1.3 Verhältniszahlen und Indizes . . . . .	10
1.4 Messung wirtschaftlicher Konzentration . . . . .	11
1.4.1 Lorenzkurve und Ginikoeffizient . . . . .	11
1.4.2 Konzentrationskurve und Konzentrationsmaße . . . . .	12
1.5 Zusammenhangs- bzw. Assoziationsmaße . . . . .	12
1.5.1 Nominalskala . . . . .	12
1.5.2 Metrische Skala . . . . .	13
1.5.3 Ordinalskala (oder besser) . . . . .	13
1.5.4 Konventionen bzgl. Stärke des Zusammenhangs . . . . .	14
1.6 Empirische lineare Regression . . . . .	14
<b>2 Wahrscheinlichkeitsrechnung</b>	<b>16</b>
2.1 Grundlagen . . . . .	16
2.1.1 Mengen, Ereignisse, $\sigma$ -Algebra . . . . .	16
2.1.2 Wahrscheinlichkeit(smaß) . . . . .	17
2.1.3 Bedingte, totale Wahrscheinlichkeit, Unabhängigkeit, Bayes . . . . .	17
2.1.4 Kombinatorik . . . . .	18
2.2 Zufallsvariable und Verteilungen . . . . .	19
2.2.1 Zufallsvariable (ZV) . . . . .	19
2.2.2 Diskrete Zufallsvariable . . . . .	20
2.2.3 Stetige Zufallsvariable . . . . .	20
2.2.4 Zweidimensionale Verteilungsfunktionen . . . . .	21
2.2.5 Erwartungswert einer Zufallsvariable . . . . .	22
2.2.6 Varianz . . . . .	23
2.2.7 Kovarianz . . . . .	23
2.2.8 Tschebyschoff-Ungleichung . . . . .	24
2.2.9 Zentraler Grenzwertsatz . . . . .	24
2.2.10 Grenzwertsatz von Poisson . . . . .	25
2.2.11 Approximationen . . . . .	25
2.2.12 Summen von Zufallsvariablen . . . . .	25
<b>3 Schließende Statistik</b>	<b>26</b>
3.1 Zufallsstichproben . . . . .	26
3.1.1 Stichprobenfunktionen bzw. Statistiken . . . . .	26
3.1.2 Spezielle Stichprobenfunktionen . . . . .	26
3.2 Punktschätzverfahren . . . . .	27
3.2.1 Eigenschaften von Schätzern . . . . .	27

3.2.2	Konstruktion von Schätzern . . . . .	27
3.3	Intervallschätzung (Konfidenzintervalle) . . . . .	28
3.3.1	Definitionen . . . . .	28
3.3.2	Spezielle Konfidenzintervalle . . . . .	28
3.4	Hypothesentests . . . . .	28
3.4.1	Konstruktion eines Tests . . . . .	29
3.4.2	Verwerfungsbereiche von Tests auf Parameter $\vartheta$ . . . . .	29
3.4.3	$p$ -Wert . . . . .	29
3.5	Klassische Parametertests . . . . .	30
3.6	Tests für Abhängigkeit bzw. Korrelationsmaße . . . . .	31
3.6.1	Normalverteilung: Test auf lineare Korrelation . . . . .	31
3.6.2	Rangdaten: Test auf monotonen Zusammenhang . . . . .	32
3.6.3	Nominaldaten: $\chi^2$ -Unabhängigkeitstest von Pearson . . . . .	32
3.6.4	Vierfeldertafeln: Exakter Test von Fisher (1970) . . . . .	33
3.7	Anpassungstests . . . . .	34
3.7.1	Allgemeines . . . . .	34
3.7.2	Kolmogoroff-Smirnoff-Test . . . . .	34
3.7.3	$\chi^2$ -Anpassungstest von Pearson . . . . .	35
3.7.4	QQ-Plots . . . . .	35
3.7.5	Shapiro-Wilk-Test (für Normalverteilung) . . . . .	36
3.8	Tests und mehr im Regressionsmodell . . . . .	37
3.8.1	Grundlagen . . . . .	37
3.8.2	Tests bzgl. Absolutglied $\beta_0$ und Anstieg $\beta_1$ . . . . .	38
3.8.3	$F$ -Test . . . . .	39
3.8.4	Prognose und Prognoseintervall . . . . .	39
<b>4</b>	<b>Appendix</b> . . . . .	<b>40</b>
4.1	Diskrete Verteilungen . . . . .	41
4.2	Stetige Verteilungen . . . . .	42
4.3	Übersicht Konfidenzintervalle . . . . .	44
4.4	Übersicht Einstichproben tests . . . . .	45
4.5	Übersicht Zweistichproben tests . . . . .	46
4.6	Verteilungsfunktion der Standardnormalverteilung . . . . .	47
4.7	Quantile der Standardnormalverteilung . . . . .	49
4.8	Quantile der $t$ -Verteilung . . . . .	50
4.9	Quantile der $\chi^2$ -Verteilung . . . . .	51
4.10	Quantile der $F$ -Verteilung . . . . .	53
4.11	Kolmogoroff-Smirnoff-Test . . . . .	58

# 1 Beschreibende Statistik

## 1.1 Grundbegriffe

- Untersuchung: Vorbereitung, Planung, Ausführung
- Grundgesamtheit  $\Omega$ : Die Menge der Objekte  $\omega$  (statistische Einheiten), auf die sich die Untersuchung bezieht, geschrieben:  $\omega \in \Omega$
- Merkmal  $X: \Omega \rightarrow S$  mit Merkmalsraum  $S$ , Realisierung  $x = X(\omega)$ .
- Skalen:
  - *Voraussetzung*:  $x$  und  $y$  seien Realisationen des Merkmals.
  - *Nominalskala (klassifikatorische/kategoriale Skala)*:  
Lediglich  $x = y$  bzw.  $x \neq y$  sind interpretierbar.
  - *Ordinalskala (Rangskala)*:  
Es existiert Ordnungsrelation:  $x = y$  oder  $x > y$  oder  $x < y$ .
  - *Intervallskala*: Ordinalskala + die absolute Differenz zwischen 2 Ausprägungen hat eine inhaltliche Bedeutung.
  - *Verhältnisskala*: Intervallskala + fester Nullpunkt
  - *metrische Skala*: Intervall- oder Verhältnisskala.
- Mächtigkeit:
  - Merkmal heißt *diskret*, falls  $\Omega$  höchstens abzählbar (endlich oder gleichmächtig zu  $\mathbb{N}$ ) ist.
  - Merkmal heißt *stetig (kontinuierlich)*, falls  $\Omega$  überabzählbar ist.
- Untersuchungseinheiten:  $\omega_1, \omega_2, \dots, \omega_n$
- Ausprägungen bzw. Originalwerte:  $x_1, x_2, \dots, x_n$ , wobei  $x_j = X(\omega_j)$ .
- Häufigkeiten der verschiedenen Ausprägungen  $\{a_i\}_{i=1}^k$  mit  $a_i \neq a_j$  für  $i \neq j$ :
  - *absolute Häufigkeit* von  $a_i$ :  $n_i = n(a_i) =$  Anzahl der Fälle, in denen  $a_i$  auftritt.
  - *relative Häufigkeit* von  $a_i$ :  $h_i = h(a_i) = n_i/n$ .
  - Graphische Darstellung: *Stab-, Balken-, Kreisdiagramm, Häufigkeitspolygon*.

⇓ **Voraussetzung:** Merkmal sei nun wenigstens *ordinalskaliert* (*metrisch* für Hist.), d. h. Sortierung  $a_1 < a_2 < \dots < a_k$

- *Summenhäufigkeit:*

$$- \text{ absolute } \sim \text{ von } a_i: N(a_i) = \sum_{j=1}^i n(a_j) = \sum_{j=1}^i n_j.$$

$$- \text{ relative } \sim \text{ von } a_i: H(a_i) = \sum_{j=1}^i h(a_j) = \sum_{j=1}^i h_j = N(a_i)/n.$$

- Histogramm

*Voraussetzung:* Metrisches Merkmal mit Merkmalsraum  $S \subset \mathbb{R}$

*Klassenbildung:* Zerlege  $S$  in  $r$  (meist gleichbreite) disjunkte Intervalle (Klassen)  $K_i$  mit

$$\begin{aligned} K_i &= (x_i^u, x_i^o], \quad \text{Klassenbreite} \quad |K_i| = x_i^o - x_i^u, \\ n(K_i) &= \text{Anzahl der Ausprägungen in } K_i, \\ h(K_i) &= n(K_i)/n. \end{aligned}$$

Das *Histogramm* (*empirische Dichte*) ist dann

$$f_n(x) = \frac{\text{relative Klassenhäufigkeit}}{\text{Klassenbreite}} = \frac{h(K_i)}{|K_i|} \quad \text{für } x \in K_i.$$

- Empirische Verteilungsfunktion

Die *empirische Verteilungsfunktion*  $F_n(x)$  ist gleich der relativen Anzahl der Realisationen, die  $\leq x$  sind, d. h.

$$F_n(x) = \begin{cases} 0 & , x < a_1 \\ H(a_i) = \sum_{j=1}^i h(a_j) & , a_i \leq x < a_{i+1} \\ 1 & , a_k \leq x \end{cases}$$

*Eigenschaften:*

1.  $F_n(x)$  monoton steigend (alias nichtfallend),  $F_n(x)$  rechtsseitig stetig.
2.  $F_n(a_j) - F_n(a_j - 0) = h(a_j)$ ,  $F_n(a_j - 0) := \lim_{\varepsilon \downarrow 0} F_n(a_j - \varepsilon)$ .

Empirische Verteilungsfunktion für klassierte Daten (lineare Interpolation):

$$F_n(x) = \begin{cases} 0 & , x < x_1^u \\ F_n(x_i^u) + \frac{x - x_i^u}{x_i^o - x_i^u} (F_n(x_i^o) - F_n(x_i^u)) & , x \in (x_i^u, x_i^o] \\ 1 & , x \geq x_r^o \end{cases}$$

oder auch für  $x \in (x_i^u, x_i^o]$ :

$$F_n(x) = \sum_{j < i} h(K_j) + (x - x_i^u) \frac{h(K_i)}{|K_i|} = F_n(x_i^u) + (x - x_i^u) f_n(x_i^o)$$

## 1 Beschreibende Statistik

- Bivariate Häufigkeit

Voraussetzung: Zwei Merkmale  $X, Y$  mit beobachteten Ausprägungspaaren

$(x_1, y_1), \dots, (x_n, y_n)$

und verschiedenen Ausprägungen

$X: a_1 < a_2 < \dots < a_k$

$Y: b_1 < b_2 < \dots < b_l$

- absolute Häufigkeit von  $(a_i, b_j)$ :  $n_{ij} = n(X = a_i, Y = b_j)$  = Anzahl der Fälle, in denen das Paar  $(a_i, b_j)$  auftritt.
- absolute Randhäufigkeit von  $a_i$ :  $n_{i\bullet}$  = Anzahl der Fälle, in denen die Ausprägung  $a_i$  in  $x_1, \dots, x_n$  auftritt, analog ist  $n_{\bullet j}$  für  $b_j$  definiert.
- Bivariate Häufigkeitstabelle/Kontingenztafel/Kreuztabelle:

X	Y				$\sum_j$
	$b_1$	$b_2$	$\dots$	$b_l$	
$a_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1l}$	$n_{1\bullet}$
$a_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2l}$	$n_{2\bullet}$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
$a_k$	$n_{k1}$	$n_{k2}$	$\dots$	$n_{kl}$	$n_{k\bullet}$
$\sum_i$	$n_{\bullet 1}$	$n_{\bullet 2}$	$\dots$	$n_{\bullet l}$	$n$

- Entsprechende relative Häufigkeiten  $h(\cdot)$  ergeben sich durch Division mit Gesamtanzahl  $n$ .
- bedingte relative Häufigkeit von  $X = a_i$ , falls  $Y = b_j$ :

$$h(X = a_i | Y = b_j) = \frac{n(X = a_i, Y = b_j)}{n(Y = b_j)} = \frac{n_{ij}}{n_{\bullet j}}.$$

- bedingte relative Häufigkeit von  $Y = b_j$ , falls  $X = a_i$ :

$$h(Y = b_j | X = a_i) = \frac{n(X = a_i, Y = b_j)}{n(X = a_i)} = \frac{n_{ij}}{n_{i\bullet}}.$$

- Bivariates Histogramm

- Klassenbildung je Komponente  $(X, Y)$ :  $K_i^X, K_j^Y$ .

$$f_n(x, y) = \frac{h((X, Y) \in K_i^X \times K_j^Y)}{|K_i^X| |K_j^Y|} \quad \text{für } x \in K_i^X \text{ und } y \in K_j^Y, \text{ sonst } 0.$$

- Aus Rechtecken werden Quader.

- Empirische bivariate Verteilungsfunktion

Beginnen mit der Kreuztabelle der relativen Häufigkeiten:

X	Y				$\sum_j$
	$b_1$	$b_2$	$\dots$	$b_l$	
$a_1$	$h_{11}$	$h_{12}$	$\dots$	$h_{1l}$	$h_{1\bullet}$
$a_2$	$h_{21}$	$h_{22}$	$\dots$	$h_{2l}$	$h_{2\bullet}$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
$a_k$	$h_{k1}$	$h_{k2}$	$\dots$	$h_{kl}$	$h_{k\bullet}$
$\sum_i$	$h_{\bullet 1}$	$h_{\bullet 2}$	$\dots$	$h_{\bullet l}$	1

Empirische bivariate Verteilungsfunktion von  $(X, Y)$ :

$$F_n(x, y) = \sum_{i: a_i \leq x} \sum_{j: b_j \leq y} h_{ij}$$

Vorgehensweise bei *klassierten* Daten: Bilineare Interpolation zwischen den Ecken; diese ergeben sich durch Aufsummierung der relativen Klassenhäufigkeiten.

## 1.2 Maßzahlen

### 1.2.1 Lagemaße

#### Arithmetisches Mittel

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \sum_{j=1}^k n_j a_j = \sum_{j=1}^k h_j a_j \quad (\text{Bei klassierten Daten ist } a_j \text{ die Klassenmitte!}).$$

#### Geometrisches Mittel

$$\bar{x}_G = \left( \prod_{i=1}^n x_i \right)^{\frac{1}{n}} = \left( \prod_{j=1}^k a_j^{n_j} \right)^{\frac{1}{n}} = \prod_{j=1}^k a_j^{h_j}.$$

#### Harmonisches Mittel

$$\bar{x}_H = \left( \frac{1}{n} \sum_{i=1}^n \frac{1}{x_i} \right)^{-1} = \left( \frac{1}{n} \sum_{j=1}^k \frac{n_j}{a_j} \right)^{-1} = \left( \sum_{j=1}^k \frac{h_j}{a_j} \right)^{-1}.$$

⇓ **Vorarbeit geordnete Stichprobe:** Sortierte Werte  $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$ .

**$\alpha$ -getrimmtes Mittel** ( $\alpha \in (0, 0.5)$ )

$$\bar{x}_\alpha = \frac{1}{n - 2h} \sum_{i=h+1}^{n-h} x_{(i)} \quad \text{mit } h = \lfloor n\alpha \rfloor \left( h \in \mathbb{N}, h \leq n\alpha < h+1 \hat{=} \text{Abrunden} \right).$$

**$\alpha$ -Quantile** ( $\alpha \in (0, 1)$ )

$$x_\alpha \begin{cases} = x_{(\lfloor n\alpha \rfloor + 1)} & n\alpha \notin \mathbb{N} \text{ oder Rangskala} \\ \in [x_{(n\alpha)}, x_{(n\alpha+1)}] \text{ bzw. } (x_{(n\alpha)} + x_{(n\alpha+1)}) / 2 & n\alpha \in \mathbb{N}, \text{ metrische (stetige) Skala} \end{cases}$$

## 1 Beschreibende Statistik

- $\alpha$ -Quantile für klassierte Größen ( $\alpha \in (0, 1)$ )

$$i = \text{Klassennummer mit } F_n(x_i^u) \leq \alpha < F_n(x_i^o),$$

$$x_\alpha = x_i^u + \frac{\alpha - F_n(x_i^u)}{f_n(x_i^o)} \quad \left( \text{Histogramm } f_n(x_i^o) = \frac{F_n(x_i^o) - F_n(x_i^u)}{x_i^o - x_i^u} = \frac{h(K_i)}{|K_i|} \right).$$

- Spezielle Quantile (Quartile)

$x_{0.25}$		1. bzw. unteres Quartil
$x_{0.5} = \text{median}(x) = x_{\text{med}} = \tilde{x}$	heißt	Median (2. Quartil)
$x_{0.75}$		3. bzw. oberes Quartil

### Modus

$$x_d = \begin{cases} \operatorname{argmax}\{n(x_1), n(x_2), \dots, n(x_k)\} \\ \text{für diskrete Merkmale, d. h. häufigster Wert} \\ \text{Mitte von } \operatorname{argmax}\{f_n(K_1), f_n(K_2), \dots, f_n(K_r)\} \\ \text{für klassierte (stetige) Merkmale, d. h. Mitte der dichtesten Klasse} \\ \text{(Klassenmitte des höchsten Histogrammrechtecks)} \end{cases}$$

## 1.2.2 Streuungsmaße

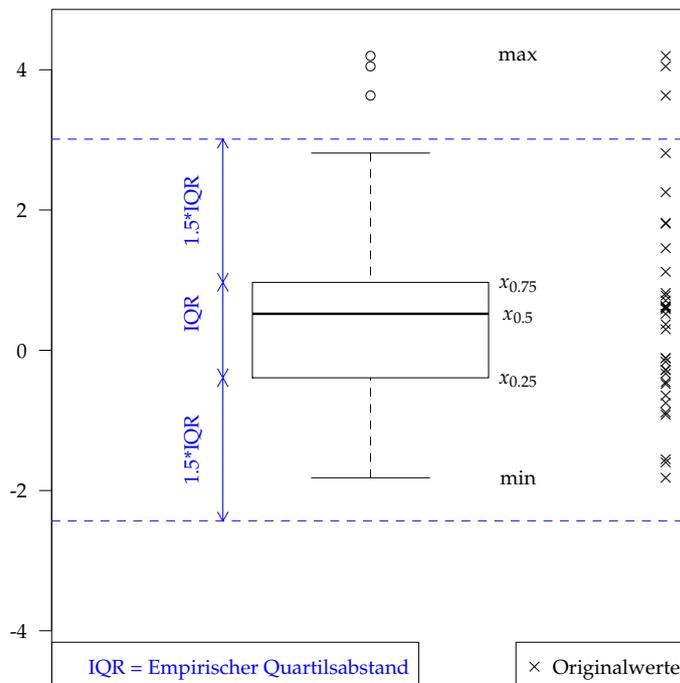
### Empirische Spannweite

$$R = x_{(n)} - x_{(1)}.$$

### Empirischer Quartilsabstand (IQR)

$$d_Q = x_{0.75} - x_{0.25}.$$

### Boxplot



**Median der absoluten Abweichungen vom Median**

$$MAD = \text{median}(|x - x_{0.5}|).$$

**Mittlere absolute Abweichung vom Median**

$$d_X = \frac{1}{n} \sum_{i=1}^n |x_i - x_{0.5}| = \frac{1}{n} \sum_{j=1}^k n_j |a_j - x_{0.5}| = \sum_{j=1}^k h_j |a_j - x_{0.5}|.$$

**Empirische Varianz**

$$\begin{aligned} \tilde{s}^2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 = \overline{x^2} - \bar{x}^2 \\ &= \frac{1}{n} \sum_{j=1}^k n_j (a_j - \bar{x})^2 = \frac{1}{n} \sum_{j=1}^k n_j a_j^2 - \bar{x}^2 = \sum_{j=1}^k h_j a_j^2 - \bar{x}^2. \end{aligned}$$

*Bemerkung:* Bei klassierten Daten setze  $a_j$  gleich der Klassenmitte von  $K_j$ .

**Stichprobenvarianz**

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

*Bemerkung:*  $\tilde{s}^2$  wird in der Beschreibenden und  $s^2$  in der Schließenden Statistik bevorzugt.

**(Empirische) Standardabweichung**

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

**Empirischer Variationskoeffizient**

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

*Mittel und Varianz bei Zerlegung in Teilgesamtheiten*

Gegeben seien  $i = 1, 2, \dots, r$  Teilgesamtheiten mit jeweils  $n_i$  Beobachtungen  $x_{ij}$ :

$$\begin{aligned} n &= \sum_{i=1}^r n_i, \quad \bar{x}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_{ij}, \quad \tilde{s}_i^2 = \frac{1}{n_i} \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2, \\ \bar{x} &= \frac{1}{n} \sum_{i=1}^r n_i \bar{x}_i \quad \left( = \frac{1}{n} \sum_{i=1}^r \sum_{j=1}^{n_i} x_{ij} \right), \\ \tilde{s}^2 &= \underbrace{\frac{1}{n} \sum_{i=1}^r n_i \tilde{s}_i^2}_{\text{interne Varianz}} + \underbrace{\frac{1}{n} \sum_{i=1}^r n_i (\bar{x}_i - \bar{x})^2}_{\text{externe Varianz}} \quad \left( = \frac{1}{n} \sum_{i=1}^r \sum_{j=1}^{n_i} (x_{ij} - \bar{x})^2 \right). \end{aligned}$$

*Effekt von Lineartransformation auf Mittel und Varianz:*

Sei  $y_i = a + bx_i$  für  $i = 1, 2, \dots, n$ .

Dann folgt für die zugehörigen Mittelwerte und Varianzen

$$\begin{aligned} \bar{y} &= a + b\bar{x}, \\ \tilde{s}_Y^2 &= b^2 \tilde{s}_X^2 \quad \text{bzw.} \quad \tilde{s}_Y = |b| \tilde{s}_X. \end{aligned}$$

### 1.3 Verhältniszahlen und Indizes<sup>1</sup>

#### Indexzahlen

Voraussetzung:  $z_t$  bezeichne eindimensionale Zahlenreihe, Index  $t$  steht für Zeit  
Messzahlen (in %) zum Basiszeitpunkt 0:

$$I_{0,t} = \frac{z_t}{z_0} \cdot 100.$$

Umbasieren (von 0 auf  $r$ ):

$$I_{r,t} = \frac{I_{0,t}}{I_{0,r}} \cdot 100.$$

Verketten (von  $r$  auf 0):

$$I_{0,t} = \frac{I_{0,r} I_{r,t}}{100}.$$

**Preis- und Mengenindizes**  $q_{i,t}$  u.  $p_{i,t}$  Menge bzw. Preis von Gut  $i$  zum Zeitpunkt  $t$

Wertindex (in %):

$$V_{0,t} = \frac{\sum_{i=1}^n q_{i,t} p_{i,t}}{\sum_{i=1}^n q_{i,0} p_{i,0}} \cdot 100.$$

Preisindex nach *Paasche* bzw. *Laspeyres* (in %; Mengen zum Zeitpunkt  $t$  bzw. 0):

$$P_{0,t}^P = \frac{\sum_{i=1}^n q_{i,t} p_{i,t}}{\sum_{i=1}^n q_{i,t} p_{i,0}} \cdot 100, \quad P_{0,t}^L = \frac{\sum_{i=1}^n q_{i,0} p_{i,t}}{\sum_{i=1}^n q_{i,0} p_{i,0}} \cdot 100.$$

Mengenindex nach *Paasche* bzw. *Laspeyres* (in %; Preise zum Zeitpunkt  $t$  bzw. 0):

$$Q_{0,t}^P = \frac{\sum_{i=1}^n q_{i,t} p_{i,t}}{\sum_{i=1}^n q_{i,0} p_{i,t}} \cdot 100, \quad Q_{0,t}^L = \frac{\sum_{i=1}^n q_{i,t} p_{i,0}}{\sum_{i=1}^n q_{i,0} p_{i,0}} \cdot 100.$$

Deflationierung:

$$Q_{0,t}^P = \frac{V_{0,t}}{P_{0,t}^L} \cdot 100 \quad \text{bzw.} \quad Q_{0,t}^L = \frac{V_{0,t}}{P_{0,t}^P} \cdot 100.$$

**Wertgewichtsmethode** für Preis- und Mengenindex nach *Laspeyres*

$$P_{0,t}^L = \sum_{i=1}^n w_{i0} \frac{p_{i,t}}{p_{i,0}} 100, \quad Q_{0,t}^L = \sum_{i=1}^n w_{i0} \frac{q_{i,t}}{q_{i,0}} 100 \quad \text{mit} \quad w_{i0} = \frac{q_{i,0} p_{i,0}}{\sum_{j=1}^n q_{j,0} p_{j,0}}$$

<sup>1</sup>Nur relevant für BWL, POL, VWL.

mit Wertgewicht  $w_{i0}$  (Umsatzanteil der Ware  $i$  in der Basisperiode 0)

$$\frac{p_{i,t}}{p_{i,0}} 100 \quad \text{und} \quad \frac{q_{i,t}}{q_{i,0}} 100 \quad \text{Preismessziffern und Mengemessziffern}$$

### Subindizes

$$P_{0,t}^L = w_{A0} P_{0,t}^A + w_{B0} P_{0,t}^B \quad \text{bzw.} \quad Q_{0,t}^L = w_{A0} Q_{0,t}^A + w_{B0} Q_{0,t}^B$$

$w_{A0}$  bzw.  $w_{B0}$  Umsatzanteil der Warengruppe  $A$  bzw.  $B$  am Gesamtumsatz

$P_{0,t}^A$  bzw.  $P_{0,t}^B$  Laspeyres-Preisindizes,  $Q_{0,t}^A$  bzw.  $Q_{0,t}^B$  Laspeyres-Mengenindizes für Warengruppe  $A$  bzw.  $B$ .

## 1.4 Messung wirtschaftlicher Konzentration<sup>2</sup>

### 1.4.1 Lorenzkurve und Ginkoeffizient

Voraussetzung: Nichtnegative (metrische) Merkmalsausprägungen

$0 \leq a_1 < a_2 < \dots < a_k$  bzw. sortierte Originalwerte  $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$ .

Dem jeweiligen Wert  $H_i$  der relativen Summenhäufigkeit ordnet man die kumulierten Anteile  $L_i$  der geordneten Merkmalsanteile zu:

$$L_i = \sum_{j=1}^i \ell_j \quad \text{mit} \quad \ell_j = \frac{a_j n_j}{\sum_{j=1}^k a_j n_j}, \quad i = 1, 2, \dots, k$$

bzw.

$$L_i = \sum_{j=1}^i \ell_j \quad \text{mit} \quad \ell_j = \frac{x_{(j)}}{\sum_{j=1}^n x_{(j)}}, \quad i = 1, 2, \dots, n$$

**Lorenzkurve:** Streckenzug, der ausgehend von  $(0,0)$  die Punkte  $(H_i, L_i)$  verbindet.

**Ginkoeffizient  $G$**  ist

$$G = \sum_{i=1}^k \underbrace{(L_i - L_{i-1})}_{=l_i} (H_{i-1} + H_i) - 1 \quad (\text{mit } H_0 = 0)$$

$$\text{bzw.} \quad G = \frac{1}{n^2 \bar{x}} \sum_{i=1}^n (2i - 1) x_{(i)} - 1.$$

Das normierte Gini-Maß ist

$$G^* = \frac{n}{n-1} G$$

und erfüllt  $0 \leq G^* \leq 1$ , während für das ursprüngliche  $G$  noch  $0 \leq G \leq \frac{n-1}{n}$  gilt.

<sup>2</sup>Nur relevant für BWL, POL, VWL.

## 1.4.2 Konzentrationskurve und Konzentrationsmaße

Der kumulierte Anteil  $C_i$  der  $i$  größten Merkmalsanteile

$$C_i = \ell_n + \ell_{n-1} + \dots + \ell_{n-i+1} = \sum_{j=1}^i c_j \quad \text{mit} \quad c_j = \ell_{n-j+1} = x_{(n-j+1)} / \sum_{j=1}^n x_{(j)}$$

bzw.  $C_i = \sum_{j=n-i+1}^n x_{(j)} / \sum_{j=1}^n x_{(j)}$  heißt *Konzentrationsrate*.

**Konzentrationskurve:** Streckenzug, der von  $(0,0)$  ausgehend die Punkte  $(i, C_i)$  bzw.  $(N_i, C_i)$  verbindet.

### Konzentrationsindizes

- **Rosenbluth-Index:**  $K_R = \frac{1}{2 \sum_{i=1}^n i c_i - 1} = \frac{1}{\frac{2}{n\bar{x}} \sum_{i=1}^n i x_{(n-i+1)} - 1} = \frac{1}{n(1-G)}$ .
- **Herfindahl-Index:**  $K_H = \sum_{i=1}^n \ell_i^2 = \sum_{i=1}^n c_i^2 \quad \left( \ell_i = x_{(i)} / \sum_{j=1}^n x_{(j)} \right)$ .
- **Exponentialindex:**  $K_E = \prod_{i=1}^n \ell_i^{\ell_i} = \prod_{i=1}^n c_i^{c_i} \quad \left( \ell_i = x_{(i)} / \sum_{j=1}^n x_{(j)} \right)$ .
- *Bemerkung:* Bei  $x_{(1)} = \dots = x_{(n)}$  sind  $K_R = K_H = K_E = 1/n$  und bei  $x_{(1)} = \dots = x_{(n-1)} = 0, x_{(n)} > 0$  sind  $K_R = K_H = K_E = 1$ .

## 1.5 Zusammenhangs- bzw. Assoziationsmaße

### 1.5.1 Nominalskala

*Voraussetzung:* Daten als Kontingenztafel gegeben.

#### Unabhängigkeit

$X$  und  $Y$  sind genau dann unabhängig, wenn für alle  $i, j$

$$h(X = a_i, Y = b_j) = h(X = a_i) h(Y = b_j) \quad \text{bzw.} \quad n_{ij} = n_{i\bullet} n_{\bullet j} / n.$$

#### Chi-Quadrat-Assoziationsmaß:

$$\chi^2 = \sum_{i=1}^k \sum_{j=1}^l \frac{(n_{ij} - n_{i\bullet} n_{\bullet j} / n)^2}{n_{i\bullet} n_{\bullet j} / n} = n \left( \sum_{i=1}^k \sum_{j=1}^l \frac{n_{ij}^2}{n_{i\bullet} n_{\bullet j}} - 1 \right)$$

(vorausgesetzt, dass  $n_{i\bullet} \neq 0, n_{\bullet j} \neq 0$  für alle  $i$  und  $j$ ).

Spezialfall  $k = l = 2$  (Vierfeldertafel):

$$\chi^2 = \frac{n(n_{11}n_{22} - n_{12}n_{21})^2}{n_{1\bullet}n_{2\bullet}n_{\bullet 1}n_{\bullet 2}}.$$

**Kontingenzkoeffizient von Cramér:**

$$V = \sqrt{\frac{\chi^2}{n(\min\{k, l\} - 1)}} \quad \text{mit } 0 \leq V \leq 1.$$

**Kontingenzkoeffizient von Pearson:**

$$C = \sqrt{\frac{\chi^2}{\chi^2 + n}} \quad \text{mit } 0 \leq C \leq C_{max} = \sqrt{\frac{\min\{k, l\} - 1}{\min\{k, l\}}}.$$

Korrigierter Kontingenzkoeffizient von Pearson:

$$C^* = \frac{C}{C_{max}} \quad \text{mit } 0 \leq C^* \leq 1.$$

### 1.5.2 Metrische Skala

*Voraussetzung:* Wertepaare auf metrischer Skala:  $(x_1, y_1), \dots, (x_n, y_n)$

**Empirische Kovarianz:**

$$\tilde{s}_{XY} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^l (a_i - \bar{x})(b_j - \bar{y}) \cdot n_{ij} = \bar{xy} - \bar{x}\bar{y}.$$

**Korrelationskoeffizient nach Bravais-Pearson:**

$$r_{XY} = \frac{\tilde{s}_{XY}}{\tilde{s}_X \tilde{s}_Y} \quad \text{mit } -1 \leq r_{XY} \leq 1.$$

*Achtung:* Es wird der lineare Zusammenhang evaluiert!

### 1.5.3 Ordinalskala (oder besser)

*Voraussetzung:* Werte auf ordinaler bzw. metrischer Skala:  $(x_1, y_1), \dots, (x_n, y_n)$

*Vorarbeit:* Ermittlung der Ränge, d.h. jeder Beobachtung  $x_i$  bzw.  $y_i$  wird die jeweilige Position innerhalb der geordneten Werte zugeordnet:

$$R(x_i) = v \quad \Leftrightarrow \quad x_i = x_{(v)}.$$

Gibt es geteilte Plätze (Bindungen), d.h.  $x_i = x_j$ ,  $i \neq j$ , so werden die Positionen aufgeteilt (Konstruktion eines mittleren Ranges): Bei bspw. zwei „Erstplatzierten“ wird  $(1 + 2)/2 = 1.5$  an jeweils beide Beobachtungen vergeben.

**Rangkorrelationskoeffizient nach Spearman**  $R_{XY} = r_{R(X),R(Y)}$ .

Allgemein (mit  $\bar{R} = (n + 1)/2$ ):

$$R_{XY} = \frac{\sum_{i=1}^n (R(x_i) - \bar{R})(R(y_i) - \bar{R})}{\sqrt{\sum_{i=1}^n (R(x_i) - \bar{R})^2 \sum_{i=1}^n (R(y_i) - \bar{R})^2}} \quad (\text{mit } -1 \leq R_{XY} \leq 1)$$

$$= \frac{\sum_{i=1}^n R(x_i) R(y_i) - n\bar{R}^2}{\sqrt{\left(\sum_{i=1}^n R(x_i)^2 - n\bar{R}^2\right) \left(\sum_{i=1}^n R(y_i)^2 - n\bar{R}^2\right)}}.$$

Im Fall keiner Bindungen:

$$R_{XY} = 1 - \frac{6 \sum_{i=1}^n (R(x_i) - R(y_i))^2}{n(n^2 - 1)}.$$

Kontingenztafel (viele Bindungen):

$$R_{XY} = \frac{\sum_{i=1}^k \sum_{j=1}^l n_{ij} R(a_i) R(b_j) - n\bar{R}^2}{\sqrt{\sum_{i=1}^k n_{i\bullet} R(a_i)^2 - n\bar{R}^2} \sqrt{\sum_{j=1}^l n_{\bullet j} R(b_j)^2 - n\bar{R}^2}}.$$

### 1.5.4 Konventionen<sup>3</sup> bzgl. Stärke des Zusammenhangs

$\{C^*,  r_{XY} ,  R_{XY} \}$	Interpretation	
$\approx 0$	keine	
$(\dots, 0.5)$	schwache	
$[0.5, 0.8)$	mittlere	Korrelation bzw. Zusammenhang
$[0.8, 1)$	starke	
1	perfekte	

## 1.6 Empirische lineare Regression

*Idee:* Modelliere linearen Zusammenhang zwischen zwei oder mehr Merkmalen.

### Einfache lineare Regression

*Voraussetzung:* Werte auf metrischer Skala:  $(x_1, y_1), \dots, (x_n, y_n)$

<sup>3</sup>Im Rahmen der Lehrveranstaltungen. Weicht in der statistischen Praxis zuweilen davon ab.

Modell:  $y_i = \beta_0 + \beta_1 x_i + u_i$

Schätzung von  $\beta_0$  und  $\beta_1$  über Methode der kleinsten Quadrate (OLS):

$$SoS = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 \rightarrow \min_{\beta_0, \beta_1} .$$

Nullsetzen der beiden Ableitungen usw. liefert

$$\hat{\beta}_1 = \frac{\bar{s}_{XY}}{\bar{s}_X^2} \quad \text{und} \quad \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} .$$

Andere Schreibweise des Modells:

$$y_i = \bar{y} + \underbrace{\hat{\beta}_1 (x_i - \bar{x})}_{=\hat{\mu}_i} + u_i .$$

Varianzzerlegung:

$$\sum (y_i - \bar{y})^2 = \sum (y_i - \hat{\mu}_i)^2 + \sum (\hat{\mu}_i - \bar{y})^2 ,$$

$$\bar{s}^2 = \bar{s}_{\hat{\mu}}^2 + \bar{s}_{\hat{\mu}}^2$$

Varianz der  $y$  = Varianz der emp. Residuen  $\hat{u}$  + Erklärte Varianz .

Bestimmtheitsmaß:

$$R^2 = \frac{\bar{s}_{\hat{\mu}}^2}{\bar{s}_y^2} = \frac{\sum (\hat{\mu}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2}$$

... und bei **einfachem** linearen Regressionsmodell:

$$R^2 = r_{XY}^2 .$$

## Multiple lineare Regression

Modell:

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + u_i \quad (k > 1) .$$

Matrixschreibweise:

$$\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & \cdots & x_{1k} \\ 1 & x_{21} & \cdots & x_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \cdots & x_{nk} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} + \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix}$$

$$\mathbf{y} = \mathbb{X} \boldsymbol{\beta} + \mathbf{u} .$$

Methode der kleinsten Quadrate usw.:

$$\hat{\boldsymbol{\beta}} = (\mathbb{X}' \mathbb{X})^{-1} \mathbb{X}' \mathbf{y}$$

$$\hat{\boldsymbol{\mu}} = \mathbb{X} \hat{\boldsymbol{\beta}} = \underbrace{\mathbb{X} (\mathbb{X}' \mathbb{X})^{-1} \mathbb{X}'}_{\text{Hat-Matrix H}} \mathbf{y} \quad , \text{H - Projektion auf Spalten von } \mathbb{X} .$$

Die Matrix  $\mathbb{X}$  muss vollen Rang haben, d. h. die Spalten von  $\mathbb{X}$  müssen linear unabhängig sein.

## 2 Wahrscheinlichkeitsrechnung

### 2.1 Grundlagen

#### 2.1.1 Mengen, Ereignisse, $\sigma$ -Algebra

- *Grundgesamtheit*:  $\Omega$  – Menge aller Elementarereignisse  $\omega$ ,
- *Ereignis*: geeignete Teilmenge von  $\Omega$ ,
- Operationen auf Ereignissen wie auf Mengen,  $A, B \subseteq \Omega$ :
  - $A \cap B = \{\omega \in \Omega : \omega \in A \text{ und } \omega \in B\}$  – „A und B treten ein“ (**Durchschnitt**).
  - $A \cup B = \{\omega \in \Omega : \omega \in A \text{ oder } \omega \in B\}$  – „mindestens eines der beiden Ereignisse tritt ein, d. h. A oder B oder beide“ (inklusives „oder“) (**Vereinigung**).
  - $A \setminus B = \{\omega \in \Omega : \omega \in A \text{ und } \omega \notin B\}$  – „A aber nicht B tritt ein“ (**Differenz**).
  - $\bar{A} (= \sim A = A^c) = \{\omega \in \Omega : \omega \notin A\}$  – „A tritt nicht ein“ – **komplementäres Ereignis (Negation)**.
- Rechenregeln,  $A, B \subseteq \Omega$ :

$$A \cup B = B \cup A,$$

$$A \cap B = B \cap A,$$

$$(A \cup B) \cup C = A \cup (B \cup C),$$

$$(A \cap B) \cap C = A \cap (B \cap C),$$

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C),$$

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C),$$

$$\overline{(A \cap B)} = \bar{A} \cup \bar{B},$$

$$\overline{(A \cup B)} = \bar{A} \cap \bar{B},$$

$$A \setminus B = A \cap \bar{B}$$

$$\overline{\bar{A}} = A.$$

- Zwei Ereignisse  $A$  und  $B$  heißen *disjunkt (unvereinbar)*, falls  $A \cap B = \emptyset$  ist.
- $\emptyset$  bzw.  $\Omega$  heißen das **unmögliche** bzw. das **sichere** Ereignis.
- Ein Mengensystem (Menge aus Mengen)  $\mathcal{A}$  in  $\Omega$  heißt eine  **$\sigma$ -Algebra (ein Ereignissystem)** in  $\Omega$ , wenn es folgende Eigenschaften hat:
  1.  $\Omega \in \mathcal{A}$ .
  2.  $A \in \mathcal{A} \Rightarrow \bar{A} \in \mathcal{A}$ .

$$3. A_n \in \mathcal{A}, n = 1, 2, \dots \Rightarrow A_1 \cup A_2 \cup \dots = \bigcup_{n=1}^{\infty} A_n \in \mathcal{A}.$$

Dann gilt auch:

$$- \emptyset \in \mathcal{A}.$$

$$- A_n \in \mathcal{A}, n = 1, 2, \dots \Rightarrow A_1 \cap A_2 \cap \dots = \bigcap_{n=1}^{\infty} A_n \in \mathcal{A},$$

$$- A, B \in \mathcal{A} \Rightarrow A \setminus B \in \mathcal{A}.$$

- Das Paar  $(\Omega, \mathcal{A})$  heißt **messbarer Raum (Messraum)**.

### 2.1.2 Wahrscheinlichkeit (Maß)

- **Wahrscheinlichkeitsmaß**  $P$  – Abbildung, die allen Ereignissen  $A \in \mathcal{A}$  eine Zahl,  $P(A)$ , zuordnet und die die folgenden Bedingungen erfüllt:

$$1. 0 \leq P(A) \leq 1,$$

$$2. P(\Omega) = 1,$$

$$3. P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n) \text{ für disjunkte } A_n \in \mathcal{A} \text{ (} A_i \cap A_j = \emptyset \text{ für } i \neq j\text{)}.$$

- Das Tripel  $(\Omega, \mathcal{A}, P)$  heißt **Wahrscheinlichkeitsraum**.

- Rechenregeln,  $A, B \in \mathcal{A}$ :

$$1. P(\bar{A}) = 1 - P(A),$$

$$2. P(\emptyset) = 0,$$

$$3. P(A) = P(A \cap B) + P(A \cap \bar{B}),$$

$$4. \text{Ist } B \subseteq A, \text{ so ist } P(B) \leq P(A),$$

$$5. P(A \cup B) = P(A) + P(B) - P(A \cap B),$$

$$6. \text{Ist } \Omega \text{ endlich, so gilt für } A \in \mathcal{A}: P(A) = \sum_{a \in A} P(\{a\}).$$

- LAPLACE-Wahrscheinlichkeit ( $\Omega$  endlich und alle Elementarereignisse besitzen dieselbe Wahrscheinlichkeit):

$$P(A) = \frac{|A|}{|\Omega|} = \frac{\text{Anzahl der für } A \text{ „günstigen Fälle“}}{\text{Anzahl der möglichen Fälle}},$$

wobei  $|A|$  die Anzahl der Elemente von  $A$  bezeichne, analog  $|\Omega|$ .

### 2.1.3 Bedingte, totale Wahrscheinlichkeit, Unabhängigkeit, Bayes

- *Bedingte Wahrscheinlichkeit*: Für Ereignisse  $A$  und  $B$  mit  $P(B) > 0$  ist

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

die **bedingte Wahrscheinlichkeit** für  $A$ , wenn bereits bekannt ist, dass das Ereignis  $B$  bereits eingetreten ist.

## 2 Wahrscheinlichkeitsrechnung

- **Unabhängigkeit:** Ereignisse  $A$  und  $B$  mit  $P(A) > 0$  und  $P(B) > 0$  sind genau dann **(stochastisch) unabhängig**, wenn

$$P(A \cap B) = P(A) \cdot P(B) \quad \Leftrightarrow \quad P(A | B) = P(A) \quad \Leftrightarrow \quad P(B | A) = P(B).$$

Ereignisse  $A_i, i = 1, 2, \dots, n$  heißen **(stochastisch) unabhängig**, wenn für jede endliche Teilmenge  $\{i_1, i_2, \dots, i_m\} \subseteq \{1, 2, \dots, n\}$  gilt, dass

$$P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_m}) = P(A_{i_1}) \cdot P(A_{i_2}) \cdot \dots \cdot P(A_{i_m}).$$

- **Multiplikationssatz für bedingte Wahrscheinlichkeiten:**  
Für  $n \geq 2$  Ereignisse  $A_1, \dots, A_n$  mit  $P(A_1 \cap A_2 \cap \dots \cap A_{n-1}) > 0$  gilt

$$\begin{aligned} P(A_1 \cap A_2 \cap \dots \cap A_n) \\ = P(A_1) \cdot P(A_2 | A_1) \cdot P(A_3 | A_1 \cap A_2) \cdot \dots \\ \cdot P(A_n | A_1 \cap A_2 \cap \dots \cap A_{n-1}). \end{aligned}$$

- **Satz von der totalen Wahrscheinlichkeit:** Für das Ereignis  $A$  und paarweise disjunkte Ereignisse  $C_1, \dots, C_n$  mit  $C_1 \cup C_2 \cup \dots \cup C_n = \Omega$  ist

$$P(A) = \sum_{i=1}^n P(A | C_i)P(C_i) \quad \left( = \sum_{i=1}^n P(A \cap C_i) \right)$$

die **totale Wahrscheinlichkeit** des Ereignisses  $A$ .

- **Satz von Bayes:** Für dieselben Ereignisse wie im vorigen Absatz gilt die **Formel von Bayes**

$$P(C_j | A) = \frac{P(A | C_j)P(C_j)}{\sum_{i=1}^n P(A | C_i)P(C_i)}.$$

### 2.1.4 Kombinatorik

*Modell:* Urne mit von 1 bis  $n$  nummerierten Kugeln, Ziehung von  $k$  Kugeln.

Man unterscheidet

- a) Ziehungen in Reihenfolge (**Variationen**)
  - a<sub>1</sub>) mit Zurücklegen
  - a<sub>2</sub>) ohne Zurücklegen
- b) Ziehungen ohne (Berücksichtigung der) Reihenfolge (**Kombinationen**)
  - b<sub>1</sub>) mit Zurücklegen
  - b<sub>2</sub>) ohne Zurücklegen

Die jeweiligen Anzahlen verschiedener Möglichkeiten sind hier zusammengefasst:

Reihenfolge	Zurücklegen	
	ja	nein
ja	$n^k$	$\frac{n!}{(n-k)!}$
nein	$\binom{n+k-1}{k}$	$\binom{n}{k}$

Dabei bedeuten

$$n! = 1 \cdot 2 \cdot \dots \cdot (n-1) \cdot n \quad (\text{Fakultät}),$$

$$\binom{n}{k} = \frac{n!}{(n-k)!k!} \quad (\text{Binomialkoeffizient}).$$

Rechenregeln für Binomialkoeffizienten ( $0 \leq k \leq n$ ):

$$\binom{n}{0} = 1, \quad \binom{n}{1} = n, \quad \binom{n}{k} = \binom{n}{n-k},$$

$$\binom{n}{k} + \binom{n}{k-1} = \binom{n+1}{k} \quad (\text{Pascalsches Dreieck}).$$

Verallgemeinerung von  $b_2$ ): Anzahl der Möglichkeiten,  $n$  verschiedene Objekte in  $k$  verschiedene Mengen vom Umfang  $n_1, \dots, n_k$  einzuteilen ( $n_1 + \dots + n_k = n$ ):

$$\frac{n!}{n_1! \dots n_k!} = \binom{n}{n_1 \dots n_k}.$$

Diese Größe heißt **Multinomialkoeffizient**.

## 2.2 Zufallsvariable und Verteilungen

### 2.2.1 Zufallsvariable (ZV)

Voraussetzung: Zufallsexperiment, beschrieben durch Wahrscheinlichkeitsraum  $(\Omega, \mathcal{A}, P)$

Eine Abbildung  $X : \Omega \rightarrow \mathbb{R}$  von der Grundgesamtheit  $\Omega$  in den Bildraum  $S = \mathbb{R}$  heißt **(reelle) Zufallsvariable**.

Der Vektor  $X = (X_1, \dots, X_k)$  mit Zufallsvariablen  $X_1, \dots, X_k$  heißt  **$k$ -dim. Zufallsvariable (Zufallsvektor)**.

**Verteilungsfunktion** von Zufallsvariable  $X$

$$F_X(x) = P(\{\omega \in \Omega : X(\omega) \leq x\}), \quad x \in \mathbb{R} \quad \text{kurz: } F(x) = P(X \leq x)$$

- $0 \leq F(x) \leq 1$  für alle  $x$ ,  $F(\infty) := \lim_{x \rightarrow \infty} F(x) = 1$ ,  $F(-\infty) := \lim_{x \rightarrow -\infty} F(x) = 0$
- $F(x)$  ist monoton wachsend in  $x$
- $F$  ist rechtsseitig stetig, d. h. für alle  $x$  gilt  $\lim_{\varepsilon \downarrow 0} F(x + \varepsilon) = F(x)$   
 $\underbrace{\hspace{10em}}_{=: F(x+0)}$

## 2 Wahrscheinlichkeitsrechnung

**Berechnung von Wahrscheinlichkeiten** Es gilt für  $a < b$ :

- $P(a < X \leq b) = F(b) - F(a)$
- $P(a \leq X \leq b) = F(b) - \underbrace{\lim_{\varepsilon \downarrow 0} F(a - \varepsilon)}_{=: F(a-0)}$
- $P(X > a) = 1 - P(X \leq a) = 1 - F(a),$   
 $P(X \geq a) = 1 - P(X < a) = 1 - F(a - 0)$
- $P(X = a) = F(a) - F(a - 0)$

### 2.2.2 Diskrete Zufallsvariable

Nimmt  $X$  höchstens abzählbar viele verschiedene Werte an, so heißt  $X$  eine **diskrete Zufallsvariable** und  $F_X$  eine **diskrete Verteilungsfunktion**.

Werte von  $X$ :  $\dots < x_{i-1} < x_i < x_{i+1} < \dots$

**Wahrscheinlichkeitsfunktion** von  $X$  ist

$$f_X(x) = \begin{cases} p_i & \text{falls } x = x_i \\ 0 & \text{falls } x \neq x_i \text{ für alle } i \end{cases} \quad \text{mit } p_i = P(X = x_i).$$

**Verteilungsfunktion** ist

$$F_X(x) = \sum_{j=1}^i f_X(x_j) = P(X = x_1) + \dots + P(X = x_i) \quad \text{für } x_i \leq x < x_{i+1}.$$

Insbesondere ist  $F(x) = 0$  für  $x < x_1$  und  $F(x) = 1$  für  $x > x_n$ .

*Beispiele für diskrete Verteilungen siehe Seite 41.*

### 2.2.3 Stetige Zufallsvariable

**Definition**

$X$  heißt **stetige Zufallsvariable**, falls für alle  $x \in \mathbb{R}$  gilt:

$$F(x) = \int_{-\infty}^x f(t) dt, \quad f(t) \geq 0 \quad \text{für alle } t \in \mathbb{R}.$$

$f$  heißt **Dichte (Wahrscheinlichkeitsdichte)** von  $X$ .

**Eigenschaften** ( $a \leq b \in \mathbb{R}$ )

- $\int_{-\infty}^{\infty} f(t) dt = 1$
- $P(a < X \leq b) = \int_a^b f(t) dt, \quad P(X > a) = \int_a^{\infty} f(t) dt$
- $P(a < X < b) = P(a \leq X \leq b), \quad P(X = a) = 0$
- Wenn  $F$  differenzierbar, dann gilt  $f(x) = F'(x)$ .

*Beispiele für stetige Verteilungen siehe Seite 42 f.*

### 2.2.4 Zweidimensionale Verteilungsfunktionen

#### Definitionen

Voraussetzung:  $(X, Y)$  2-dim. Zufallsvariable:

$$F(x, y) = P(\{\omega \in \Omega : X(\omega) \leq x, Y(\omega) \leq y\}) = P(X \leq x, Y \leq y)$$

ist die **zweidimensionale Verteilungsfunktion** des Zufallsvektors  $(X, Y)$

- $F(x, \infty)$  ist die **Randverteilung von  $X$** ,
- $F(\infty, y)$  ist die **Randverteilung von  $Y$**

mit

$$\begin{aligned} F(x, \infty) &= P(X \leq x) =: F_X(x), \\ F(\infty, y) &= P(Y \leq y) =: F_Y(y). \end{aligned}$$

Falls  $(X, Y)$  **diskret**, d. h. nimmt höchstens abzählbar viele verschiedene Wertepaare an, heißt  $f(x_i, y_j) = P(X = x_i, Y = y_j)$  **Wahrscheinlichkeitsfunktion** von  $(X, Y)$ .

$(X, Y)$  heißt **stetig**, falls

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y f(s, t) ds dt$$

mit  $f(x, y) \geq 0$  für alle  $x, y$ .  $f$  heißt *Dichte* von  $(X, Y)$ .

#### Eigenschaften einer zweidimensionalen Verteilungsfunktion

- $0 \leq F(x, y) \leq 1$ ,
- $\lim_{x \rightarrow -\infty} F(x, y) = 0$ ,  $\lim_{y \rightarrow -\infty} F(x, y) = 0$ ,  $\lim_{\substack{x \rightarrow \infty \\ y \rightarrow \infty}} F(x, y) = 1$ ,
- Monotonie:  $x_1 \leq x_2, y_1 \leq y_2 \Rightarrow F(x_1, y_1) \leq F(x_2, y_2)$ ,
- rechtsseitig stetig:  $F(x, y) = F(x + 0, y) = F(x, y + 0) = F(x + 0, y + 0)$ ,
- $x_1 < x_2, y_1 < y_2$ :

$$P(x_1 < X \leq x_2, y_1 < Y \leq y_2) = F(x_2, y_2) - F(x_2, y_1) - F(x_1, y_2) + F(x_1, y_1) \geq 0.$$

#### Bedingte Verteilungen

Voraussetzung:  $f$  Wahrscheinlichkeitsfunktion/Dichte von  $(X, Y)$ ,  $f_X, f_Y$  jeweils die Wahrscheinlichkeitsfunktion/Dichte von  $X, Y$  (Randverteilung):

$$f(x | y) = \frac{f(x, y)}{f_Y(y)} \quad \text{für } f_Y(y) > 0$$

heißt „bedingte Wahrscheinlichkeitsfunktion/Dichte von  $X$ , wenn  $Y$  den Wert  $y$  annimmt“, analog  $f(y | x)$ .

## 2 Wahrscheinlichkeitsrechnung

### Unabhängigkeit von Zufallsvariablen

*Definition:* Zufallsvariablen  $X_1, \dots, X_n$  heißen **unabhängig**, falls für alle  $x_1, \dots, x_n$

$$F(x_1, \dots, x_n) = \prod_{i=1}^n F(x_i).$$

Äquivalente Definitionen:

- diskrete ZV: für alle  $x_1, \dots, x_n$  gilt

$$P(X_1 = x_1, \dots, X_n = x_n) = \prod_{i=1}^n P(X_i = x_i)$$

- stetige ZV: für alle  $x_1, \dots, x_n$  gilt

$$f(x_1, \dots, x_n) = \prod_{i=1}^n f(x_i)$$

- 2-dim. Zufallsvariable,  $f_X, f_Y$  Wahrscheinlichkeitsfunktion/Dichte:

$$\text{für alle } x, y \text{ mit } f_Y(y) > 0 \text{ gilt } f(x | y) = f_X(x)$$

### Summen von Zufallsvariable bei Unabhängigkeit

*Voraussetzung:*  $X, Y$  unabhängige Zufallsvariable

- diskret:  $P(X + Y = z) = \sum_t P(X = z - t)P(Y = t)$
- stetig:  $f_{X+Y}(z) = \int_{-\infty}^{\infty} f_X(z - t) f_Y(t) dt$

### 2.2.5 Erwartungswert einer Zufallsvariable

**Definition:**

$$E(X) = \begin{cases} \sum x_i P(X = x_i) & X \text{ diskrete Zufallsvariable} \\ \int_{-\infty}^{\infty} x f(x) dx & X \text{ stetige Zufallsvariable} \end{cases}$$

**Eigenschaften:**

- $f$  sei Wahrscheinlichkeits- oder Dichtefunktion: Ist  $f$  symmetrisch bzgl.  $m$ , d. h.  $f(m + x) = f(m - x)$  für alle  $x$ , so ist  $E(X) = m$ , falls existent.
- Es sei  $Y = h(X)$ .

$$\text{Ist } X \text{ diskret, so gilt (falls existent) } E(Y) = E(h(X)) = \sum_i h(x_i) f(x_i).$$

$$\text{Ist } X \text{ stetig, so gilt (falls existent) } E(Y) = E(h(X)) = \int_{-\infty}^{\infty} h(x) f(x) dx.$$

$$\text{Beispiel: } Y = aX + b: \quad E(aX + b) = aE(X) + b.$$

- Es sei  $Y = h(X)$  und  $h(\cdot)$  konvexe Funktion. Dann ist  $E(h(X)) \geq h(E(X))$  – folgt über die JENSENSche Ungleichung.

$$\text{Beispiel: } E(X^2) \geq E(X)^2.$$

- Sind  $X_1, \dots, X_n$  Zufallsvariable mit jeweils existierendem Erwartungswert, so ist

$$E\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n E(X_i).$$

Sind die Zufallsvariablen  $X_1, \dots, X_n$  zusätzlich noch unabhängig, so ist auch

$$E\left(\prod_{i=1}^n X_i\right) = \prod_{i=1}^n E(X_i).$$

### 2.2.6 Varianz

*Voraussetzung:* Zufallsvariable  $X$  mit Verteilungsfunktion  $F$

**Definition:** Varianz von  $X$  ist

$$\text{Var}(X) = E([X - E(X)]^2).$$

Man schreibt auch  $\sigma^2 = \text{Var}(X)$ .

$\sigma = \sqrt{\text{Var}(X)}$  heißt **Standardabweichung**.

**Eigenschaften**

- Verschiebungssatz (mit  $\mu := E(X)$ ):

$$\text{Var}(X) = E([X - \mu]^2) = E(X^2) - \mu^2.$$

- Für alle  $a, b \in \mathbb{R}$  ist

$$\text{Var}(aX + b) = a^2 \text{Var}(X).$$

- Sind die Zufallsvariablen  $X_1, \dots, X_n$  unkorreliert und existieren jeweils die Varianzen, so ist

$$\text{Var}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \text{Var}(X_i).$$

- Für alle  $a, b \in \mathbb{R}$  und zwei **beliebige** Zufallsvariablen  $X$  und  $Y$  gilt

$$\text{Var}(aX + bY) = a^2 \text{Var}(X) + 2ab \text{Cov}(X, Y) + b^2 \text{Var}(Y).$$

Für  $\text{Cov}()$  siehe unten. Für unkorrelierte  $X$  und  $Y$  ist natürlich  $\text{Cov}(X, Y) = 0$ .

### 2.2.7 Kovarianz

*Voraussetzung:* Zufallsvariablen  $X$  und  $Y$  mit Verteilungsfunktionen  $F_X$  und  $F_Y$

**Definition:** Kovarianz von  $X$  und  $Y$  ist

$$\text{Cov}(X, Y) = E([X - E(X)][Y - E(Y)]).$$

Man schreibt auch  $\sigma_{XY} = \text{Cov}(X, Y)$ .

## 2 Wahrscheinlichkeitsrechnung

### Eigenschaften

- „Verschiebungssatz“:

$$\text{Cov}(X, Y) = E([X - E(X)][Y - E(Y)]) = E(XY) - E(X)E(Y).$$

- Für alle  $a, b, c, d \in \mathbb{R}$  ist

$$\text{Cov}(aX + b, cY + d) = ac\text{Cov}(X, Y).$$

- Cauchy-Schwarzsche Ungleichung:

$$\text{Cov}(X, Y)^2 \leq \text{Var}(X) \cdot \text{Var}(Y).$$

- Lineare Korrelation (siehe auch Bravais-Pearsonscher Korrelationskoeffizient):

$$\rho = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X) \cdot \text{Var}(Y)}}.$$

- Für  $\rho = 0$  sagt man, dass  $X$  und  $Y$  unkorreliert sind.

### 2.2.8 Tschebyschhoff-Ungleichung

*Voraussetzung:* Zufallsvariable  $X$  mit der Verteilungsfunktion  $F$  mit endlicher Varianz, d. h.  $0 < \text{Var}(X) < \infty$ .

Es gilt für alle  $\varepsilon > 0$ :

$$P(|X - \mu| \geq \varepsilon) \leq \frac{\text{Var}(X)}{\varepsilon^2}$$

bzw. äquivalent

$$P(|X - \mu| < \varepsilon) \geq 1 - \frac{\text{Var}(X)}{\varepsilon^2}.$$

### 2.2.9 Zentraler Grenzwertsatz

**Zentraler Grenzwertsatz (ZGWS):** Sei  $X_1, X_2, \dots$  eine Folge von Zufallsvariablen, die alle unabhängig und identisch verteilt sind, d. h. es gilt insbesondere  $E(X) = \mu$  und  $\text{Var}(X) = \sigma^2$  (mit  $0 < \sigma^2 < \infty$ ) für alle  $X_i, i = 1, 2, \dots$ . Sei weiter  $\bar{X}_n = 1/n \sum_{i=1}^n X_i$  das Stichprobenmittel (arithmetisches Mittel). Dann gilt:

$$\lim_{n \rightarrow \infty} P\left(\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq z\right) = \Phi(z) \quad (\text{oder auch } \lim_{n \rightarrow \infty} P\left(\frac{\sum X_i - n\mu}{\sqrt{n}\sigma} \leq z\right) = \Phi(z)),$$

wobei  $\Phi(z)$  die Verteilungsfunktion der Standard-Normalverteilung ist (siehe Normalverteilung allgemein auf Seite 43 und Bedeutung sowie Tabellierung von  $\Phi$  auf 47 f.).

**Spezialfall ZGWS Moivre-Laplace**

Vor.: unabhängige  $X_i \sim B(1, p)$ ,  $\sum_{i=1}^n X_i =: Y_n \sim B(n, p)$  sowie  $a, b \in \mathbb{N}$  mit  $a < b$  und  $n$  groß

$$P(a < Y_n \leq b) \approx \Phi\left(\frac{b + 0.5 - np}{\sqrt{np(1-p)}}\right) - \Phi\left(\frac{a + 0.5 - np}{\sqrt{np(1-p)}}\right).$$

Bemerkung: Der Term „+0.5“ heißt *Stetigkeitskorrektur* und dient der Erhöhung der Approximationsgüte.

**2.2.10 Grenzwertsatz von Poisson**

$Y_n \sim B(n, p)$ : Mit  $p \rightarrow 0$  und  $np \rightarrow \lambda > 0$  für  $n \rightarrow \infty$  konvergiert  $Y_n$  gegen  $Z \sim \text{Pois}(\lambda)$ .

**2.2.11 Approximationen**

Verteilung	Approximation durch	Bedingung (Faustregel)
$H(N, M, n)$	$B(n, p)$ , $p = \frac{M}{N}$	$\frac{n}{N} < 0.05$
$H(N, M, n)$	$\text{Pois}(\lambda)$ , $\lambda = n \frac{M}{N}$	$n > 10$ , $\frac{M}{N} < 0.05$ , $\frac{n}{N} < 0.05$
$B(n, p)$	$\mathcal{N}(\mu, \sigma^2)$ , $\mu = np$ , $\sigma^2 = np(1-p)$	$np(1-p) \geq 9$
$B(n, p)$	$\text{Pois}(\lambda)$ , $\lambda = np$	$n \geq 20$ , $p \leq 0.1$ , $np \leq 10$
$\text{Pois}(\lambda)$	$\mathcal{N}(\mu, \sigma^2)$ , $\mu = \lambda$ , $\sigma^2 = \lambda$	$\lambda \geq 9$
$\chi_n^2$	$(\mathcal{N}(\mu, \sigma^2))^2 / 2$ , $\mu = \sqrt{2n-1}$ , $\sigma^2 = 1$	$n > 50$
$\chi_n^2$	$\mathcal{N}(\mu, \sigma^2)$ , $\mu = n$ , $\sigma^2 = 2n$	$n > 200$
$t_n$	$\mathcal{N}(\mu, \sigma^2)$ , $\mu = 0$ , $\sigma^2 = n/(n-2)$	$n > 30$

**2.2.12 Summen von Zufallsvariablen**

Vor.:  $X_1, \dots, X_n$  unabhängige Zufallsvariable.

Verteilung Summand $X_i$	Verteilung Summe $\sum X_i$
$\mathcal{N}(\mu_i, \sigma_i^2)$ für $\mathcal{N}(\mu, \sigma^2)$	$\mathcal{N}(\sum \mu_i, \sum \sigma_i^2)$ speziell $\bar{X} \sim \mathcal{N}(\mu, \sigma^2/n)$
$B(1, p)$	$B(n, p)$
$B(n_i, p)$	$B(\sum n_i, p)$
$\text{Exp}(\lambda)$	$\text{Erlang}(n, \lambda) = \Gamma(n, \lambda)$

# 3 Schließende Statistik

## 3.1 Zufallsstichproben

Ein Merkmal sei auf einer Grundgesamtheit gemäß einer Zufallsvariablen  $X$  verteilt. Aus dieser Grundgesamtheit wird eine Stichprobe von  $n$  Elementen zufällig ausgewählt. Die Ergebnisse  $(x_1, x_2, \dots, x_n)$  sind dann Realisierungen der  $n$ -dimensionalen Zufallsvariablen  $(X_1, X_2, \dots, X_n)$ . Alle Zufallsvariablen  $X_i, i = 1, 2, \dots, n$ , haben dieselbe Verteilung wie  $X$ . Man spricht daher auch von einer Stichprobe aus (der Verteilungsfunktion)  $F_X$ . Da alle Stichprobenvariablen  $X_i, i = 1, 2, \dots, n$ , identisch verteilt sind, haben sie insbesondere auch alle den Erwartungswert  $E(X)$  und die Varianz  $Var(X)$ . Weiter sind wegen der zufälligen Auswahl der Elemente aus der Grundgesamtheit die Zufallsvariablen  $X_1, X_2, \dots, X_n$  alle unabhängig voneinander. Eine solche  $n$ -dimensionale Zufallsvariable  $(X_1, X_2, \dots, X_n)$  nennen wir eine **Zufallsstichprobe**.

### 3.1.1 Stichprobenfunktionen bzw. Statistiken

Eine Funktion  $g$  einer Stichprobe, d. h. eine Abbildung

$$(X_1, X_2, \dots, X_n) \longrightarrow g(X_1, X_2, \dots, X_n)$$

nennt man Stichprobenfunktion bzw. **Statistik**.

### 3.1.2 Spezielle Stichprobenfunktionen

Sei  $(X_1, X_2, \dots, X_n)$  eine Stichprobe aus  $X$  mit  $E(X) = \mu$  und  $Var(X) = \sigma^2$ :

Stichprobenfunktion	Erwartungswert	Varianz
Summe $\sum_{i=1}^n X_i$	$n\mu$	$n\sigma^2$
Stichprobenmittel $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$	$\mu$	$\frac{\sigma^2}{n}$
Standardisiertes Stichprobenmittel $\frac{\bar{X} - \mu}{\sigma} \sqrt{n}$	0	1
Empirische Varianz $\tilde{S}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$	$\frac{n-1}{n} \sigma^2$	$\frac{(n-1) 2\sigma^4}{n^2}$
Stichprobenvarianz $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$	$\sigma^2$	$\frac{2\sigma^4}{n-1}$

## 3.2 Punktschätzverfahren

### 3.2.1 Eigenschaften von Schätzern

Seien  $\hat{\vartheta}$ ,  $\hat{\vartheta}_1$ ,  $\hat{\vartheta}_2$  Schätzer für einen Parameter  $\vartheta$  und  $n$  die Größe der Stichprobe. Dann heißt:

$\hat{\vartheta}$  erwartungstreu (unverzerrt) für  $\vartheta$ , wenn  $E(\hat{\vartheta}) = \vartheta$ ,

$\hat{\vartheta}$  asymptotisch erwartungstreu für  $\vartheta$ , wenn  $\lim_{n \rightarrow \infty} E(\hat{\vartheta}) = \vartheta$ ,

$\hat{\vartheta}_1$  wirksamer als  $\hat{\vartheta}_2$  ( $E(\hat{\vartheta}_1) = E(\hat{\vartheta}_2) = \vartheta$ ), wenn  $Var(\hat{\vartheta}_1) < Var(\hat{\vartheta}_2)$ ,

$\hat{\vartheta}_1$  wirksamst bzw. effizient ( $E(\hat{\vartheta}_1) = \vartheta$ ), wenn  $Var(\hat{\vartheta}_1) = \inf_{\hat{\vartheta}: E(\hat{\vartheta}) = \vartheta} Var(\hat{\vartheta})$ ,

$\hat{\vartheta}$  konsistent für  $\vartheta$ , wenn für  $\varepsilon > 0$  gilt:  $\lim_{n \rightarrow \infty} P(|\hat{\vartheta} - \vartheta| > \varepsilon) = 0$ .

Insbesondere ist  $\hat{\vartheta}$  konsistent, wenn  $E(\hat{\vartheta}) \rightarrow \vartheta$  und  $Var(\hat{\vartheta}) \rightarrow 0$  für  $n \rightarrow \infty$ .

### 3.2.2 Konstruktion von Schätzern

#### Maximum-Likelihood-Methode

Sei  $(X_1, X_2, \dots, X_n)$  eine Zufallsstichprobe aus  $X$ , d. h. alle  $X_i$  haben dieselbe Wahrscheinlichkeitsfunktion bzw. Dichtefunktion  $f_{\vartheta}(x)$ , wobei  $\vartheta = (\vartheta_1, \dots, \vartheta_k)$  der Vektor  $k$  unbekannter Verteilungsparameter ist. Dann heißt die Funktion

$$L(x_1, \dots, x_n; \vartheta) = \prod_{i=1}^n f_{\vartheta}(x_i) = f_{\vartheta}(x_1) \cdot f_{\vartheta}(x_2) \cdot \dots \cdot f_{\vartheta}(x_n)$$

Likelihoodfunktion und ihr (natürlicher) Logarithmus

$$\ln L(x_1, \dots, x_n; \vartheta) = \sum_{i=1}^n \ln f_{\vartheta}(x_i)$$

Loglikelihoodfunktion. Als Schätzer  $\hat{\vartheta}$  für  $\vartheta$  wird dann der Vektor

$$\hat{\vartheta} = \underset{\vartheta}{\operatorname{argmax}} \ln L(x_1, \dots, x_n; \vartheta) \quad \text{verwendet.}$$

#### Momenten-Schätzmethode

Unter der Voraussetzung, dass die theoretischen Momente Funktionen der Parameter  $\vartheta$  sind, werden die empirisch beobachteten Momente mit den theoretischen Momenten gleichgesetzt und, falls möglich, nach den Parametern aufgelöst:

$$E(X^k) = \overline{X^k}.$$

Beispiel: Gleichverteilung auf  $[a, b]$  – Schätzung von  $a$  und  $b$ .

$$E(X) = \frac{a+b}{2}, \quad E(X^2) = Var(X) + E(X)^2 = \dots = \frac{a^2 + ab + b^2}{3},$$

$$\bar{X} = \frac{\hat{a} + \hat{b}}{2}, \quad \overline{X^2} = \frac{\hat{a}^2 + \hat{a}\hat{b} + \hat{b}^2}{3},$$

$$\hat{b} = \bar{X} + \sqrt{3(\overline{X^2} - \bar{X}^2)} = \bar{X} + \sqrt{3} \tilde{S}, \quad \hat{a} = \bar{X} - \sqrt{3} \tilde{S}.$$

### 3.3 Intervallschätzung (Konfidenzintervalle)

#### 3.3.1 Definitionen

Aus einer Zufallsstichprobe  $(X_1, X_2, \dots, X_n)$  werden zwei Stichprobenfunktionen  $\hat{\vartheta}_u = T_1(X_1, X_2, \dots, X_n)$  und  $\hat{\vartheta}_o = T_2(X_1, X_2, \dots, X_n)$  so bestimmt, dass gilt

$$P_{\vartheta}(\hat{\vartheta}_u \leq \vartheta \leq \hat{\vartheta}_o) \geq 1 - \alpha,$$

wobei  $0 < \alpha < 1$ . Solch ein Intervall  $[\hat{\vartheta}_u, \hat{\vartheta}_o]$  nennt man **zweiseitiges**  $(1 - \alpha)$ -Konfidenzintervall,  $\alpha$  die Fehlerwahrscheinlichkeit und  $(1 - \alpha)$  das Konfidenzniveau.

$[\hat{\vartheta}_u, \infty) = [T_1(X_1, X_2, \dots, X_n), \infty)$  heißt **einseitiges unteres Konfidenzintervall** zum Niveau  $1 - \alpha$ , falls gilt

$$P_{\vartheta}(\hat{\vartheta}_u \leq \vartheta) \geq 1 - \alpha \quad \forall \vartheta \in \Theta.$$

$(-\infty, \hat{\vartheta}_o] = (-\infty, T_2(X_1, X_2, \dots, X_n)]$  heißt **einseitiges oberes Konfidenzintervall** zum Niveau  $1 - \alpha$ , falls gilt

$$P_{\vartheta}(\vartheta \leq \hat{\vartheta}_o) \geq 1 - \alpha \quad \forall \vartheta \in \Theta.$$

#### 3.3.2 Spezielle Konfidenzintervalle

Ein Überblick ist auf Seite 44 gegeben. Einseitige Konfidenzintervalle lassen sich aus den dort gegebenen zweiseitigen ableiten.

### 3.4 Hypothesentests

Ein Verfahren, das auf der Basis einer Stichprobe eine Entscheidung über Annahme oder Ablehnung einer Hypothese erlaubt, heißt statistischer Test bzw. (kurz) Test. Zur genauen Formulierung eines Testproblems gehören eine sogenannte Nullhypothese ( $H_0$ ) und eine Alternativhypothese ( $H_1$ ).

Bei parametrischen Tests geht es um die Entscheidung, ob ein Parameter  $\vartheta$  einer Verteilung in einem gegebenen Parameterbereich  $\Theta_0$  liegt oder eben in einem anderen Parameterbereich  $\Theta_1$ . Dabei gilt, natürlich,  $\Theta_0 \cap \Theta_1 = \emptyset$  und häufig (aber nicht immer)  $\Theta_0 \cup \Theta_1 = \Theta$ . Ein Testproblem beginnt mit

$$H_0 : \vartheta \in \Theta_0 \quad \text{gegen} \quad H_1 : \vartheta \in \Theta_1.$$

#### Terminologie des Testens

- Folgende Fehler bei der Entscheidung können begangen werden:

**Fehler 1. Art:** Entscheide mich für  $H_1$ , aber  $H_0$  ist richtig.

**Fehler 2. Art:** Entscheide mich für  $H_0$ , aber  $H_1$  ist richtig.

Entscheidung	Realität	
	$\vartheta \in \Theta_0$	$\vartheta \in \Theta_1$
$H_0$ nicht verwerfen	kein Fehler	Fehler 2. Art
$H_1$ annehmen	Fehler 1. Art	kein Fehler

- Gütefunktion  $G : \Theta \rightarrow [0, 1]$  gibt die Wahrscheinlichkeit  $G(\vartheta)$  an,  $H_1$  anzunehmen, falls der Parameter den Wert  $\vartheta$  besitzt

*Anforderung:* Gütefunktion für  $\vartheta \in \Theta_0$  klein und für  $\vartheta \in \Theta_1$  groß.

- **Teststrategie:** Gebe obere Schranke  $\alpha$  für die maximale Wahrscheinlichkeit des Fehlers 1. Art vor – übliche Werte sind  $\alpha \in \{0.01, 0.05, 0.1\}$ .  $\alpha$  nennt man auch das nominale **Signifikanzniveau** des anzuwendenden Tests,

*Bezeichnung:*  $\alpha$ -Niveau-Test für  $H_0$ , falls die Wahrscheinlichkeit für einen Fehler 1. Art stets kleiner oder gleich  $\alpha$  ist.

*Achtung:* Bei einem  $\alpha$ -Niveau-Test wird nur der Fehler 1. Art kontrolliert, nicht der Fehler 2. Art!

- **Hinweis:** Diejenige Hypothese, die bestätigt werden soll, muss als  $H_1$  gewählt werden. Aber **Vorsicht:** Tests der Form  $H_0 : \mu \neq \mu_0 \leftrightarrow H_1 : \mu = \mu_0$  sprengen den Rahmen der Grundausbildung und sollten daher vorerst vermieden werden.

### 3.4.1 Konstruktion eines Tests

- Hypothese(n) aufstellen.
- Fehlerwahrscheinlichkeit 1. Art  $\alpha$  festlegen.
- Teststatistik  $T$  identifizieren.
- Ablehnungsbereich  $C$  so festlegen, dass  $P_{H_0}(T \in C) \leq \alpha$ .
- Entscheidung treffen:  $H_0$  wird verworfen, wenn der Wert der Teststatistik  $T$  bei der vorliegenden Stichprobe im Ablehnungsbereich  $C$  liegt.

### 3.4.2 Verwerfungsbereiche von Tests auf Parameter $\vartheta$

Bezeichne  $T$  die Teststatistik eines Tests auf einen Parameter  $\vartheta$  und  $q_\alpha$  das  $\alpha$ -Quantil der Verteilung der Teststatistik.

$H_0$	$H_1$	$H_0$ ablehnen, wenn
$\vartheta \leq \vartheta_0$	$\vartheta > \vartheta_0$	$T > c = q_{1-\alpha}$
$\vartheta \geq \vartheta_0$	$\vartheta < \vartheta_0$	$T < c = q_\alpha$
$\vartheta = \vartheta_0$	$\vartheta \neq \vartheta_0$	$T < c_1 = q_{\alpha/2}$ oder $T > c_2 = q_{1-\alpha/2}$

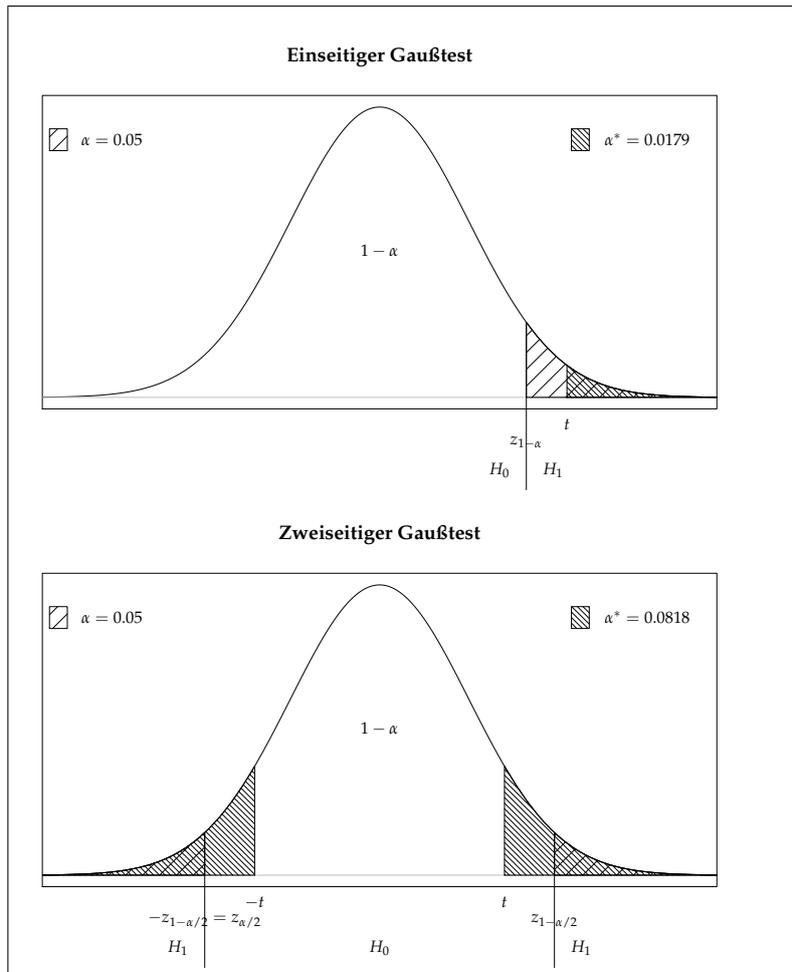
### 3.4.3 $p$ -Wert

*Begriffsbestimmung:*  $p$ -Wert bzw. empirisches Signifikanzniveau  $\alpha^*$  ist die Wahrscheinlichkeit, mit der die Prüfgröße  $T$  einen Wert annimmt, der unter  $H_0$  genauso unplausibel wie oder noch unplausibler ist als der beobachtete Wert  $t$ .

$\rightsquigarrow$  Je kleiner  $\alpha^*$ , desto unplausibler ist  $H_0$ , d. h. desto „signifikanter“ ist die Abweichung der Stichprobe von  $H_0$ .

Vorgehen (bei Statistiksoftware):

- $\alpha$  festlegen,
- Software angewandt auf Daten liefert  $\alpha^*$ ,
- $\alpha^* < \alpha \Rightarrow H_0$  verwerfen bzw.  $\alpha^* \geq \alpha \Rightarrow H_0$  nicht verwerfen.



### 3.5 Klassische Parametertests

Übersichten über Ein- und Zweistichprobentests sind auf den Seiten 45 und 46 gegeben. Gewisse Spezialfälle seien hier behandelt.

#### Zweistichprobentest bei verbundenen Stichproben

*Voraussetzung:*  $X$  und  $Y$  sind abhängig, z. B.  $X_i$  und  $Y_i$  werden am selben Merkmalsträger gemessen, Normalvert., Variablen innerhalb der Teilstichproben  $X_1, \dots, X_n$  und  $Y_1, \dots, Y_n$  unabhängig.

*Hypothesen:*  $H_0: \mu_X = \mu_Y \leftrightarrow H_1: \mu_X \neq \mu_Y$

*Vorgehen:* Betrachten  $D_i = X_i - Y_i$  für  $i = 1, 2, \dots, n$

Daher:

$$T = \frac{\bar{D}}{\sqrt{\frac{1}{n-1} \sum_{i=1}^n (D_i - \bar{D})^2}} \sqrt{n} \sim t_{n-1}$$

*Bemerkung:*  $(n-1)\widehat{Var}(D) = (n-1) \left( \widehat{Var}(X) + \widehat{Var}(Y) - 2\widehat{Cov}(X, Y) \right)$

### 3.6 Tests für Abhängigkeit bzw. Korrelationsmaße

↪ Wären die Stichproben unabhängig ( $\rightarrow \text{Cov}(X, Y) = 0$ ), so wäre  $\widehat{\text{Cov}}(X, Y)$  rund 0 und damit wäre man beim unverbundenen  $t$ -Test (siehe Seite 46). Würde man fälschlich den unverbundenen  $t$ -Test benutzen, so würde man beim Schätzen der Varianz einen systematischen Fehler in der Größenordnung von  $2\widehat{\text{Cov}}(X, Y)$  machen.

#### Zweistichprobentest mit Nichtstandardhypothesen

In der Liste auf Seite 46 werden Hypothesen der Form

$$\begin{aligned} H_0: \mu_X = \mu_Y &\leftrightarrow H_1: \mu_X \neq \mu_Y, \\ H_0: \sigma_X^2 = \sigma_Y^2 &\leftrightarrow H_1: \sigma_X^2 \neq \sigma_Y^2 \end{aligned}$$

inkl. der jeweiligen einseitigen Varianten behandelt. Etwas allgemeiner sind

$$\begin{aligned} H_0: \mu_X - \mu_Y = \Delta &\leftrightarrow H_1: \mu_X - \mu_Y \neq \Delta, \\ H_0: \sigma_X^2 / \sigma_Y^2 = \delta &\leftrightarrow H_1: \sigma_X^2 / \sigma_Y^2 \neq \delta \end{aligned}$$

mit vorgegebenen Werten  $\Delta$  bzw.  $\delta$ . Mit den neuen Prüfgrößen

$$T = \frac{(\bar{X} - \bar{Y}) - \Delta}{\text{„Nenner“}} \quad \text{bzw.} \quad T = \frac{S_X^2}{\delta S_Y^2}$$

sind die Spalten „Verteilung von  $T$  unter  $H_0$ “ und „kritische Werte, d. h.  $H_0$  ablehnen falls“ wieder anwendbar. „Nenner“ steht hier stellvertretend für die Version des jeweiligen Tests. Für  $\Delta = 0$  bzw.  $\delta = 1$  ergeben sich jeweils die Standardfälle der Tabelle auf Seite 46.

## 3.6 Tests für Abhängigkeit bzw. Korrelationsmaße

*Voraussetzung:* Es seien  $X$  und  $Y$  zwei Merkmale.

*Testproblem:*  $H_0: X$  und  $Y$  unabhängig  $\leftrightarrow H_1: X$  und  $Y$  nicht unabhängig

*Gegeben:* Realisierungen  $(x_i, y_i), i = 1, \dots, n$  einer unabhängigen Zufallsstichprobe  $(X_i, Y_i)$ .

### 3.6.1 Normalverteilung: Test auf lineare Korrelation

*Voraussetzung:*  $(X, Y)$  2-dim. normalverteilt mit

$$E(X) = \mu_X, \text{Var}(X) = \sigma_X^2, E(Y) = \mu_Y, \text{Var}(Y) = \sigma_Y^2, \text{Corr}(X, Y) = \rho.$$

Man beachte, dass (nur) bei Normalverteilung gilt:  $X$  und  $Y$  unabhängig  $\leftrightarrow \rho = 0$

Schätzer für  $\rho$ : empirischer Korrelationskoeffizient von Bravais-Pearson  $\hat{\rho} = \frac{S_{XY}}{S_X S_Y}$ , wobei  $S_{XY}, S_X, S_Y$  jeweils Stichprobenkovarianz und Stichprobenstandardabweichung für  $X$  bzw.  $Y$  sind.

*Hypothesen:*  $H_0: \rho = 0 \leftrightarrow H_1: \rho \neq 0$

*Prüfgröße*  $T = \sqrt{n-2} \frac{\hat{\rho}}{\sqrt{1-\hat{\rho}^2}}$  unter  $H_0$  ist  $T \sim t_{n-2}$ , d. h. für  $|T| > t_{n-2; 1-\alpha/2}$  wird  $H_0$  verworfen.

**Bemerkung** Für die einseitigen Tests

$H_0: \rho = 0 \leftrightarrow H_1: \rho > 0$  und  $H_0: \rho = 0 \leftrightarrow H_1: \rho < 0$

wird  $H_0$  bei  $T > t_{n-2; 1-\alpha}$  bzw.  $T < t_{n-2; \alpha}$  verworfen.

### 3.6.2 Rangdaten: Test auf monotonen Zusammenhang

Bezeichnung:  $R(X_i)$  – Rang der  $i$ -ten Beobachtung innerhalb  $X_1, \dots, X_n$

Voraussetzung: Es gibt keine Bindungen, d. h. jede Beobachtungen tritt genau **ein** Mal auf – siehe auch Seite 14.

Dann ist der Rangkorrelationskoeffizient gegeben über

$$\hat{R} = 1 - \frac{6 \sum_{i=1}^n (R(X_i) - R(Y_i))^2}{n^3 - n}$$

Hypothesen

$H_0$ :  $X$  und  $Y$  unabhängig  $\leftrightarrow H_1$ : zwischen  $X$  und  $Y$  monotoner Zusammenhang

$H_0$ :  $R = 0$   $\leftrightarrow H_1$ :  $R \neq 0$

Unter  $H_0$  ist  $\hat{R}$  approximativ normalverteilt, wobei  $E(\hat{R}) = 0$  und  $Var(\hat{R}) = 1/(n - 1)$ .

Vergleich von  $T = \sqrt{n - 1} \cdot \hat{R}$  für große  $n$  ( $\geq 100$ ) mit den Quantilen der Standardnormalverteilung, sonst entsprechende Tabellen.

Hypothesen	$H_0$ verwerfen, wenn
$H_0: R = 0 \leftrightarrow H_1: R \neq 0$	$ T  > z_{1-\alpha/2}$
$H_0: R = 0 \leftrightarrow H_1: R > (<) 0$	$T > z_{1-\alpha}$ ( $T < z_\alpha$ )

### 3.6.3 Nominaldaten: $\chi^2$ -Unabhängigkeitstest von Pearson

Voraussetzung:  $X$  und  $Y$  diskret mit nur endlich vielen Ausprägungen  $a_1, \dots, a_k$  bzw.  $b_1, \dots, b_l$ .

Hypothesen:  $H_0$ :  $X$  und  $Y$  unabhängig  $\leftrightarrow H_1$ :  $X$  und  $Y$  abhängig

$n_{ij}$  gebe an, wie oft das Paar  $(a_i, b_j)$  in der Stichprobe  $(x_1, y_1), \dots, (x_n, y_n)$  auftritt (siehe S. 6 o. 12).

Kontingenztafel der absoluten Häufigkeiten:

X	Y				$\Sigma_j$
	$b_1$	$b_2$	$\dots$	$b_l$	
$a_1$	$n_{11}$	$n_{12}$	$\dots$	$n_{1l}$	$n_{1\bullet}$
$a_2$	$n_{21}$	$n_{22}$	$\dots$	$n_{2l}$	$n_{2\bullet}$
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
$a_k$	$n_{k1}$	$n_{k2}$	$\dots$	$n_{kl}$	$n_{k\bullet}$
$\Sigma_i$	$n_{\bullet 1}$	$n_{\bullet 2}$	$\dots$	$n_{\bullet l}$	$n$

Schätzer für  $P(X = a_i, Y = b_j)$ ,  $P(X = a_i)$ ,  $P(Y = b_j)$  sind  $\frac{n_{ij}}{n}$ ,  $\frac{n_{i\bullet}}{n}$  bzw.  $\frac{n_{\bullet j}}{n}$ .

Bezeichnung:  $\hat{n}_{ij} := \frac{n_{i\bullet} n_{\bullet j}}{n}$

Indifferenztafel: Ersetze in obiger Kontingenztafel die  $n_{ij}$  durch  $\hat{n}_{ij}$  bei fixierten Randhäufigkeiten.

Unter  $H_0$  ist  $\hat{n}_{ij} \approx n_{ij}$  (vgl. Seite 12).

Prüfgröße:  $T = \sum_{i=1}^k \sum_{j=1}^l \frac{(n_{ij} - \hat{n}_{ij})^2}{\hat{n}_{ij}}$ .

Unter  $H_0$  ist  $\lim_{n \rightarrow \infty} P(\chi^2 \leq y) = F_{\chi^2_{(k-1)(l-1)}}(y)$

mit  $F_{\chi^2_{(k-1)(l-1)}}(y)$  als Verteilungsfunktion einer  $\chi^2$ -Verteilung mit  $(k-1)(l-1)$  Freiheitsgraden.

Entscheidungsregel: Ist  $T > \chi^2_{(k-1)(l-1); 1-\alpha}$ , so wird  $H_0$  abgelehnt.

**Bemerkungen**

1. Bequemere Schreibweise:  $T = n \left( \sum_{i=1}^k \sum_{j=1}^l \frac{n_{ij}^2}{n_{i\bullet} \cdot n_{\bullet j}} - 1 \right)$

2. Vereinfachte Berechnung für Vierfeldertafeln:  $\chi^2 = \frac{n(n_{11}n_{22} - n_{12}n_{21})^2}{n_{1\bullet} \cdot n_{\bullet 1} \cdot n_{2\bullet} \cdot n_{\bullet 2}}$

**Faustregel:** Es sollte  $\frac{n_{i\bullet} \cdot n_{\bullet j}}{n} \geq 5$  für alle  $i, j$  sein, d. h.  $\hat{n}_{ij} \geq 5$ . Ist für ein oder mehrere  $(i, j)$  dies verletzt, so sollten Zeilen bzw. Spalten der Kontingenztafel geeignet zusammengelegt werden, so dass die Bedingung dann erfüllt ist.

Mit Klasseneinteilung kann dieser Test auch auf stetige Zufallsvariable angewendet werden.

**3.6.4 Vierfeldertafeln: Exakter Test von Fisher (1970)**

Voraussetzung: Merkmale X und Y haben nur jeweils zwei Ausprägungen

**Bemerkung:** Es läßt sich auch einseitig testen, d. h.

Hypothesen  $H_0$ : X und Y unabhängig  $\leftrightarrow H_1$ : X und Y abhängig  
 $\leftrightarrow H'_1$ :  $P(Y = y_1 | X = x_1) > (<) P(Y = y_1)$

	Y		
	$y_1$	$y_2$	
X			
$x_1$	$m$	$n - m$	$n$
$x_2$	$M - m$	$N - M - (n - m)$	$N - n$
	$M$	$N - M$	$N$

Teststatistik: Anzahl der Paare  $(x_1, y_1)$ , d. h.  $T = m$

Verteilung unter  $H_0$  (Hypergeometrische Verteilung!)

$$P_{H_0}(T = m) = \frac{\binom{M}{m} \binom{N - M}{n - m}}{\binom{N}{n}}$$

Wertebereich der Teststatistik T:  $\{\underline{m}, \underline{m} + 1, \dots, \bar{m}\}$  mit  $\underline{m} = \max\{0, n - (N - M)\}$  und  $\bar{m} = \min\{n, M\}$ .

„unkritischer“ Bereich:  $\{k_1, k_1 + 1, \dots, k_2\}$  mit  $\underline{m} < k_1 < k_2 < \bar{m}$

kritischer Bereich:  $K := \{\underline{m}, \underline{m} + 1, \dots, k_1 - 1\} \cup \{k_2 + 1, k_2 + 2, \dots, \bar{m}\}$

$P_{H_0}(T < k_1) \leq \alpha/2$ ,  $P_{H_0}(T > k_2) \leq \alpha/2 \rightsquigarrow P_{H_0}(k_1 \leq T \leq k_2) \geq 1 - \alpha$  (Gleichheit lässt sich nur schwerlich erreichen, da Verteilung diskret).

### 3 Schließende Statistik

Bestimmung von  $k_1$  und  $k_2$ , wobei  $H(m)$  die Verteilungsfunktion der Hypergeometrischen Verteilung bezeichnet:

$$\begin{aligned}k_1 &= k_1(\alpha) = \max \{m \in \mathbb{N} : P_{H_0}(T < m) \leq \alpha/2\} \\ &= \max \{m \in \mathbb{N} : H(m-1) \leq \alpha/2\},\end{aligned}$$

$$\begin{aligned}k_2 &= k_2(\alpha) = \min \{m \in \mathbb{N} : P_{H_0}(T > m) \leq \alpha/2\} \\ &= \min \{m \in \mathbb{N} : H(m) \geq 1 - \alpha/2\}.\end{aligned}$$

*Entscheidungsregel:* Ist  $T \in K$ , so wird  $H_0$  abgelehnt.

Im einseitigen Fall besteht  $K$  nur aus  $\{\underline{m}, \underline{m} + 1, \dots, \tilde{k}_1 - 1\}$  oder  $\{\tilde{k}_2 + 1, \tilde{k}_2 + 2, \dots, \bar{m}\}$ .

*Bemerkung:* Im einseitigen Fall ist es bequemer, sofort den  $p$ -Wert  $\alpha^* = P_{H_0}(T \leq m)$  zu berechnen und diesen dann wie üblich mit dem vorab festgelegten Fehlerniveau  $\alpha$  zu vergleichen.

## 3.7 Anpassungstests

(engl. *goodness-of-fit tests*)

### 3.7.1 Allgemeines

*Voraussetzung:*  $x_1, \dots, x_n$  seien die Realisierung einer unabhängigen Zufallsstichprobe  $X_1, \dots, X_n$  mit  $X_i \sim F$  ( $F$  sei die unbekannte Verteilungsfunktion) für alle  $i = 1, \dots, n$

*Testproblem*

$$H_0 : F = F_0 \quad \leftrightarrow \quad H_1 : F \neq F_0$$

Dabei ist  $F_0$  eine bekannte Verteilungsfunktion.

**Achtung:** Es wird nicht (bei einem Irrtumsniveau  $\alpha$ ) bewiesen, dass  $F_0$  die „richtige“ Verteilungsfunktion ist, sondern es wird (nur) geprüft, ob die Daten signifikant gegen  $F_0$  sprechen!

### 3.7.2 Kolmogoroff-Smirnoff-Test

*Voraussetzung:*  $X$  ist **stetige** Zufallsvariable.

*Bezeichnung:* empirische Verteilungsfunktion  $\hat{F}_n$ , d. h.  $\hat{F}_n(x)$  = relative Anzahl von Beobachtungen aus  $x_1, \dots, x_n$ , die kleiner oder gleich  $x$  sind.

$$\text{Teststatistik: } D = \sup_{x \in \mathbb{R}} |\hat{F}_n(x) - F_0(x)|$$

Die asymptotische Verteilung von  $D$  unter  $H_0$  ist tabelliert. **Sie hängt nicht von  $F_0$  ab (wenn  $F_0$  stetig ist)!**  $c$  wird als  $(1 - \alpha)$ -Quantil der Verteilung tabelliert (siehe Seite 58).

*Testentscheidung:* Ist  $D > c_{n;1-\alpha}$ , so wird  $H_0$  abgelehnt.

*Bemerkungen:*

1. Kolmogoroff bewies 1933:  $\lim_{n \rightarrow \infty} P \left( D < \frac{x}{\sqrt{n}} \right) = \sum_{k=-\infty}^{\infty} (-1)^k e^{-2k^2 x^2}$
2. Smirnoff übertrug das 1939 auf zwei emp. Verteilungsfunktionen (Zweistichprobenfall).

Praktische Berechnung von  $D$

$$D = \max_{1 \leq i \leq n} \{ \hat{F}_n(x_i) - F_0(x_i), F_0(x_i) - \hat{F}_n(x_{i-1}) \}, \hat{F}_n(x_0) := 0.$$

	Excel	SPSS	STATA
ks.test(x, ...)	<addon only>	[Analysieren->NP Tests->K-S]	ksmirnov

### 3.7.3 $\chi^2$ -Anpassungstest von Pearson

Voraussetzung:  $X$  habe  $r$  verschiedene Ausprägungen  $t_1, \dots, t_r$ .

Testproblem:

$$H_0 : P(X = t_i) = p_i \text{ für } i = 1, \dots, r \quad \leftrightarrow \quad H_1 : P(X = t_i) \neq p_i \text{ für mindestens ein } i$$

Bezeichnung:  $N_i$  = Anzahl der Beobachtungen an, die gleich  $t_i$ ;  $E(N_i) = np_i$  unter  $H_0$ .

$$\text{Prüfgröße: } Q = \sum_{i=1}^r \frac{(N_i - np_i)^2}{np_i}.$$

Es gilt unter der Nullhypothese (Stichprobenumfang  $n$ ):

$$\lim_{n \rightarrow \infty} P(Q \leq x) = F_{\chi_{r-1}^2}(x),$$

wobei  $F_{\chi_{r-1}^2}(x)$  die Verteilungsfunktion einer  $\chi^2$ -Verteilung mit  $r - 1$  Freiheitsgraden bezeichnet.

Testentscheidung: Ist  $Q > \chi_{r-1; 1-\alpha}^2$ , so wird  $H_0$  abgelehnt.

**Beachte:** Damit die asymptotische Verteilungsannahme gerechtfertigt ist, sollte  $np_i \geq 5$  (unter  $H_0$ ) für **alle**  $i$  gelten. Falls für ein  $i$  die Schranke 5 unterschritten wird  $\rightsquigarrow$  Klassenbildung (siehe unten).

**Erweiterung auf stetige Verteilungen:** (bzw. diskrete Verteilung mit einer großen Zahl von Ausprägungen wie z. B. Poisson-, geometrische Verteilung etc.) Zerlegung des Wertebereichs von  $X$  in  $r$  disjunkte Klassen  $T_1, \dots, T_r$ . Unter  $H_0$  sei  $p_i = P(X \in T_i) > 0$ ,  $i = 1, \dots, r$ .  $N_i$  gebe die Anzahl der Stichprobenelemente an, die in der Klasse  $T_i$  liegen. Die Prüfgröße  $Q$  wird wie oben konstruiert. Erneut ist  $Q$  unter  $H_0$  approximativ  $\chi^2$ -verteilt mit  $r - 1$  Freiheitsgraden (hier ist  $r$  die Klassenanzahl). Die Klassen  $T_1, \dots, T_r$  dürfen nicht von den Daten abhängen.

**ACHTUNG:** Hängt die Verteilung  $F_0$  von  $l$  unbekanntem Parametern ab, so werden diese (**mittels der gruppierten Daten**) geschätzt. In der Prüfgröße wird  $p_i$  durch  $\hat{p}_i$  ersetzt. Die asymptotische Verteilung der Teststatistik  $Q$  unter  $H_0$  ist dann  $\chi_{r-1-l}^2$ .

### 3.7.4 QQ-Plots

(Quantil-Quantil-Plots)

Voraussetzung: geordnete Zufallsstichprobe  $X_{(1)}, \dots, X_{(n)}$  bzw. Stichprobe  $x_{(1)}, \dots, x_{(n)}$ .

Ansatz: Vermutete Basisverteilungsfunktion  $F_0(y)$  mit  $E(Y) = 0$  und  $Var(Y) = 1$ , d. h. vermutlich ist  $F_X(x) = F_0((x - \mu)/\sigma)$  mit gegebenenfalls noch zu schätzenden  $\mu$  und  $\sigma$ .

(i) **Ordnungsstatistiken**

Idee: Vergleich  $x_{(i)}$  mit  $E(Y_{(i)})$  für alle  $i$

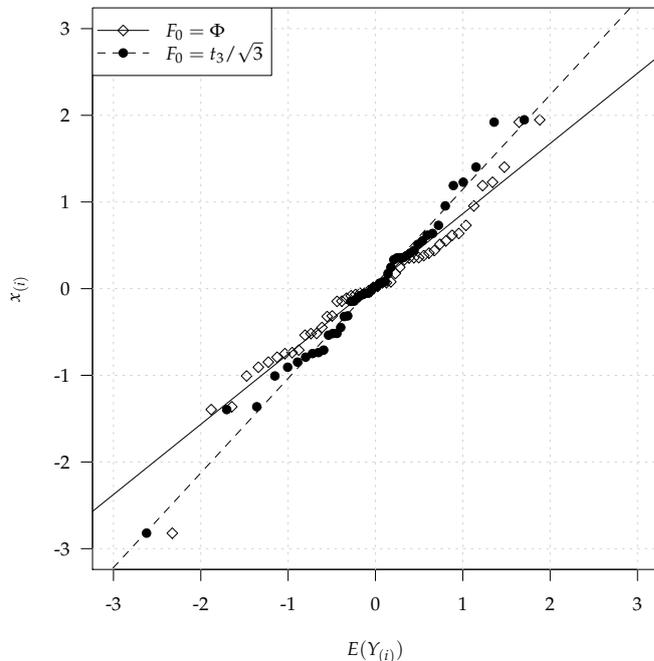
**Approximation:**  $E(Y_{(i)}) \approx F_0^{-1}((i - 0.5)/n)$

### 3 Schließende Statistik

#### (ii) Quantile

Kollektion von empirischen Quantilen, wie z. B. die 9 Dezile  $\tilde{x}_{0.1}, \dots, \tilde{x}_{0.9}$ , und Vergleich mit den theoretischen (also vermuteten), wie z. B.  $F_0^{-1}(0.1), \dots, F_0^{-1}(0.9)$  usw.

**Beispiel:** QQ-Plot für die tägliche Aktienrendite eines Monats,  $F_0$  ist entweder die Standardnormalverteilung bzw. eine standardisierte  $t$ -Verteilung mit 3 Freiheitsgraden



**Bemerkung:** Je näher die Datenpunkte an der Regressionsgeraden liegen, desto besser passt die Verteilung  $F_X(x) = F_0((x - \mu)/\sigma)$  zu den Daten. Darauf basieren auch einige Tests.

#### 3.7.5 Shapiro-Wilk-Test (für Normalverteilung)

*Voraussetzung:* geordnete Zufallsstichprobe  $X_{(1)}, \dots, X_{(n)}$

*Hypothesen:*  $H_0: X \sim \mathcal{N}(\mu, \sigma^2) \leftrightarrow H_1: X \not\sim \mathcal{N}(\mu, \sigma^2)$

**Bemerkung:**  $\mu$  und  $\sigma^2$  müssen nicht bekannt sein.

**Technik, Bezeichnungen usw.:**

geordnete Stichprobe  $z_1 < z_2 < \dots < z_n$

standardnormalverteilter Zufallsvariabler,

$E(z_i) = m_i$  – Erwartungswert der  $i$ -ten „Ordnungsstatistik“,

$\text{Cov}(z_i, z_j) = v_{ij}$  – Kovarianz zweier solcher,

$$\mathbb{V} = \begin{pmatrix} v_{11} & \dots & v_{1n} \\ \vdots & \ddots & \vdots \\ v_{n1} & \dots & v_{nn} \end{pmatrix}, \quad \mathbf{m} = \begin{pmatrix} m_1 \\ \vdots \\ m_n \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} X_{(1)} \\ \vdots \\ X_{(n)} \end{pmatrix}.$$

Für  $X \sim \mathcal{N}(\mu, \sigma^2)$  ist  $X_{(i)} = \mu + \sigma m_i + \text{kleiner Fehler}$ ,

Verallgemeinerte MKQ-Schätzung:

$$\hat{\mu} = \bar{X}, \hat{\sigma} = \frac{\mathbf{m}' \mathbb{V}^{-1} \mathbf{X}}{\mathbf{m}' \mathbb{V}^{-1} \mathbf{m}},$$

$$\text{Hilfsgrößen } \mathbf{a} = \begin{pmatrix} a_1 \\ \vdots \\ a_n \end{pmatrix} = \frac{\mathbf{m}' \mathbb{V}^{-1}}{(\mathbf{m}' \mathbb{V}^{-1} \mathbb{V}^{-1} \mathbf{m})^{1/2}},$$

$$\text{Teststatistik } W = \frac{\left( \sum_{i=1}^n a_i X_{(i)} \right)^2}{\sum_{i=1}^n (X_{(i)} - \bar{X})^2} \quad \left( \approx \frac{\hat{\sigma}^2}{S^2} \right),$$

kritischer Bereich  $(0, w_\alpha) \rightsquigarrow W < w_\alpha \Rightarrow H_0$  ist zu verwerfen.

*Bemerkung:* Die Konstanten  $m_i, v_{ij}$  und  $a_i$  lassen sich nur numerisch ermitteln. Diese gibt es sowohl tabelliert als auch innerhalb von Statistiksoftware.

	Excel	SPSS	STATA
shapiro.test(x)	<addon only>	[Analysieren->NP Tests->S-W]	swilk

## 3.8 Tests und mehr im Regressionsmodell

### 3.8.1 Grundlagen

*Regressionsmodell:*

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, n,$$

$$E(\varepsilon_i) = 0,$$

$$\text{Var}(\varepsilon_i) = \sigma^2 \quad \text{– Varianz hängt nicht von } i \text{ ab (Homoskedastizität),}$$

$$\text{Cov}(\varepsilon_i, \varepsilon_j) = 0 \quad \text{– Residuen sind nicht (auto)korreliert}$$

$$\left( \varepsilon_i \sim \mathcal{N}(0, \sigma^2) \quad \text{– normalverteilte Residuen} \right).$$

MKQ-Schätzer für  $\beta_0$  und  $\beta_1$ : (siehe auch Seite 15)

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x}, \quad \hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(Y_i - \bar{Y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \begin{cases} S_{xY} / s_x^2 \\ \tilde{S}_{xY} / \tilde{s}_x^2 \end{cases}$$

mit

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad \text{bzw.} \quad \tilde{s}_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2,$$

$$S_{xY} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(Y_i - \bar{Y}) \quad \text{bzw.} \quad \tilde{S}_{xY} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(Y_i - \bar{Y}).$$

$$\text{Schätzer für } \sigma^2: \hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2 = \frac{n-1}{n-2} \left( S_Y^2 - \frac{(S_{xY})^2}{s_x^2} \right) = S_Y^2 (1 - R^2) \frac{n-1}{n-2}.$$

$$\text{bzw. } \hat{\sigma}^2 = \frac{n}{n-2} \left( \tilde{S}_Y^2 - \frac{(\tilde{S}_{xY})^2}{\tilde{s}_x^2} \right) = \frac{n}{n-2} (\tilde{S}_Y^2 - \hat{\beta}_1 \tilde{S}_{xY}) = \tilde{S}_Y^2 (1 - R^2) \frac{n}{n-2}.$$

### 3 Schließende Statistik

$\hat{\beta}_0, \hat{\beta}_1$  und  $\hat{\sigma}^2$  sind erwartungstreu.

Varianzen von  $\hat{\beta}_0, \hat{\beta}_1$  und  $\hat{\sigma}^2$ :

$$\begin{aligned} \text{Var}(\hat{\beta}_0) &= \sigma^2 \left( \frac{1}{n} + \frac{\bar{x}^2}{(n-1)s_x^2} \right) = \frac{\sigma^2}{n} \left( 1 + \frac{\bar{x}^2}{\bar{s}_x^2} \right), \\ \text{Var}(\hat{\beta}_1) &= \frac{\sigma^2}{(n-1)s_x^2} = \frac{\sigma^2}{n\bar{s}_x^2}, \\ \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) &= -\frac{\sigma^2 \bar{x}}{(n-1)s_x^2} = -\frac{\sigma^2 \bar{x}}{n\bar{s}_x^2}, \\ \text{Var}(\hat{\sigma}^2) &= \frac{2\sigma^4}{n-2}. \end{aligned}$$

Somit sind  $\hat{\beta}_0, \hat{\beta}_1$  und  $\hat{\sigma}^2$  auch konsistent.

#### 3.8.2 Tests bzgl. Absolutglied $\beta_0$ und Anstieg $\beta_1$

*Bemerkung:* Um die Varianzen der Schätzer  $\hat{\beta}_0$  und  $\hat{\beta}_1$  zu schätzen, ersetzt man in den obigen Formeln einfach  $\sigma^2$  durch den Schätzer  $\hat{\sigma}^2$ .

##### (I) Absolutglied $\beta_0$

*Hypothesen:*  $H_0: \beta_0 = a \leftrightarrow H_1: \beta_0 \neq a$

*Prüfgröße:*

$$T_{\beta_0} = \frac{\hat{\beta}_0 - a}{\sqrt{\widehat{\text{Var}}(\hat{\beta}_0)}} = \frac{\hat{\beta}_0 - a}{\hat{\sigma} \sqrt{1/n + \bar{x}^2 / [(n-1)s_x^2]}} = \frac{\hat{\beta}_0 - a}{\hat{\sigma} \sqrt{1 + \bar{x}^2 / \bar{s}_x^2}} \sqrt{n}$$

Bei normalverteilten Residuen, d. h.  $\varepsilon_i \sim \mathcal{N}(0, \sigma^2)$ , gilt unter der Nullhypothese  $T_{\beta_0} \sim t_{n-2}$ .

$\rightsquigarrow |T_{\beta_0}| > t_{n-2; 1-\alpha/2} \Rightarrow H_0$  wird abgelehnt.

**Bemerkung:** Sind die Residuen  $\varepsilon_i$  nicht normalverteilt, so ist  $T_1$  unter  $H_0$  approximativ normalverteilt (meist nutzt man auch hier die  $t$ -Verteilung, da diese zu kleineren Ablehnungsbereichen führt). Dabei sollte  $\sum_{i=1}^n (x_i - \bar{x})^2 \rightarrow \infty$  für  $n \rightarrow \infty$  gelten.

##### (II) Anstieg $\beta_1$

*Hypothesen:*  $H_0: \beta_1 = b \leftrightarrow H_1: \beta_1 \neq b$

*Prüfgröße:*

$$T_{\beta_1} = \frac{\hat{\beta}_1 - b}{\sqrt{\widehat{\text{Var}}(\hat{\beta}_1)}} = \frac{\hat{\beta}_1 - b}{\hat{\sigma}} \sqrt{n-1} s_x = \frac{\hat{\beta}_1 - b}{\hat{\sigma}} \sqrt{n} \bar{s}_x$$

Bei  $\varepsilon_i \sim \mathcal{N}(0, \sigma^2)$  gilt unter der Nullhypothese  $T_{\beta_1} \sim t_{n-2}$ .

$\rightsquigarrow |T_{\beta_1}| > t_{n-2; 1-\alpha/2} \Rightarrow H_0$  wird abgelehnt.

**Bemerkung:** Wie bei  $T_{\beta_0}$  gilt das für  $\varepsilon_i \not\sim \mathcal{N}(0, \sigma^2)$  nur approximativ.

### 3.8.3 F-Test

Typischer Output von Statistik-Software beim Regressionsmodell ist die **Varianzanalysetabelle** (engl. ANOVA[analysis of variance] table).

Streuungstyp	Summe	Freiheitsgrade	Mittlerer quadratischer Fehler	Prüfgröße
Erklärte Streuung	$SQE = \sum(\hat{\beta}_0 + \hat{\beta}_1 x_i - \bar{Y})^2$	1	$MQE = \frac{SQE}{1}$	$F = \frac{MQE}{MQR}$
Reststreuung	$SQR = \sum(Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2$	$n - 2$	$MQR = \frac{SQR}{n-2} = \hat{\sigma}^2$	
Gesamtstreuung	$SQT = \sum(Y_i - \bar{Y})^2$	$n - 1$	$S_Y^2$	

Die Tabelle illustriert, welchen Beitrag das Regressionsmodell bei der Streuungszersetzung leistet. Die „Gesamtstreuung“  $SQT$  wird um den Beitrag der „Erklärten Streuung“  $SQE$  zur sogenannten „Reststreuung“  $SQR$  reduziert. Von  $SQR$  führt dann der Weg direkt zur Schätzung der Residualvarianz  $\sigma^2 = Var(\varepsilon_i)$ . Der Quotient  $F$  vergleicht unmittelbar Erklärte und Reststreuung. Es lässt sich nun zeigen, dass

$$F = T_{\beta_1}^2 \quad (\text{siehe Prüfgröße in 3.8.2(II) für } b = 0),$$

$$F = \frac{R^2}{1 - R^2} (n - 2)$$

und  $F \sim F_{1, n-2}$  unter  $H_0: \beta_1 = 0 \Leftrightarrow$  einfache lineare Regression nicht nötig.

Mittels dieses  $F$ -Tests lässt sich prüfen, ob das lineare Regressionsmodell „signifikant“ ist. Dies funktioniert auch bei multiplen Regressionsmodellen (siehe dazu die Matrixschreibweise auf Seite 15) mit mehr als einem Regressanden. Dann steigt die Zahl der Freiheitsgrade im Zähler auf eben diese Anzahl, während die Freiheitsgrade im Nenner um eben diesen Betrag fallen. Die neue Nullhypothese lautet dann  $H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$  ( $k > 1$ ,  $k = 1$  – ein Regressand). Die Teststatistik  $F$  ist dann unter  $H_0$   $F_{k, n-k-1}$ -verteilt.

### 3.8.4 Prognose und Prognoseintervall

Prognose für  $Y_T = f(x_T)$ :  $\hat{Y}_T = \hat{\beta}_0 + \hat{\beta}_1 x_T$

Konstruktion eines Prognoseintervalls:

Prognosefehler:

$$\begin{aligned} \hat{\varepsilon}_T &= Y_T - \hat{Y}_T = \beta_0 + \beta_1 x_T + \varepsilon_T - (\hat{\beta}_0 + \hat{\beta}_1 x_T) \\ &= \beta_0 - \hat{\beta}_0 + (\beta_1 - \hat{\beta}_1) x_T + \varepsilon_T. \end{aligned}$$

Varianz des Prognosefehlers ( $E(\hat{\varepsilon}_T) = 0$ ):

$$\begin{aligned} Var(\hat{\varepsilon}_T) &= Var(\hat{\beta}_0) + x_T^2 Var(\hat{\beta}_1) + 2x_T Cov(\hat{\beta}_0, \hat{\beta}_1) + Var(\varepsilon_T) \\ Var(\hat{\varepsilon}_T) &= \sigma^2 \left( \frac{1}{n} \left( 1 + \frac{\bar{x}^2}{\bar{s}_x^2} \right) + \frac{x_T^2}{n\bar{s}_x^2} - 2x_T \frac{\bar{x}}{n\bar{s}_x^2} + 1 \right) \\ &= \sigma^2 \left( 1 + \frac{1}{n} \left( 1 + \frac{(x_T - \bar{x})^2}{\bar{s}_x^2} \right) \right) \end{aligned}$$

$\rightsquigarrow$  Prognoseintervall für  $Y_T$  bei normalverteilten Residuen  $\varepsilon_i$  (sonst approximativ):

$$\hat{Y}_T - \hat{\sigma} \sqrt{1 + \frac{1}{n} \left( 1 + \frac{(x_T - \bar{x})^2}{\bar{s}_x^2} \right)} t_{n-2; 1-\alpha/2} < Y_T < \hat{Y}_T + \hat{\sigma} \sqrt{1 + \frac{1}{n} \left( 1 + \frac{(x_T - \bar{x})^2}{\bar{s}_x^2} \right)} t_{n-2; 1-\alpha/2}$$

$t_{n-2; 1-\alpha/2}$  ist das Quantil einer Studentverteilung mit  $n - 2$  Freiheitsgraden.

## 4 Appendix

Im Anhang finden Sie eine Reihe von Tabellen, so

1. einen Überblick über einige Verteilungen,
2. Konfidenzintervalle,
3. Tests,
4. die Verteilungsfunktion der Standardnormalverteilung,
5. die Quantile der Standardnormal-, der studentischen  $t$ -, der  $\chi^2$ - und der (Fisher)  $F$ -Verteilung,
6. kritische Werte des Kolmogoroff-Smirnoff-Tests.

## 4.1 Diskrete Verteilungen

Verteilung	Wahrscheinlichkeitsfunktion $f(m)$	Parameter- raum	Erwartungs- wert $\mu = E(X)$	Varianz $\sigma^2 = E([X - \mu]^2)$
Binomial <sup>§</sup> $B(n, p)$	$\binom{n}{m} p^m (1-p)^{n-m}$ $m \in \{0, 1, \dots, n\}$	$0 < p < 1$ $n \in \{1, 2, \dots\}$	$np$	$np(1-p)$
Hyper- geometrisch $H(N, M, n)$	$\frac{\binom{M}{m} \binom{N-M}{n-m}}{\binom{N}{n}}$ $m \in \{m_{\min}, m_{\min}+1, \dots, m_{\max}\}$ , $m_{\min} := \max\{0, n - (N-M)\}$ , $m_{\max} := \min\{n, M\}$	$N \in \{1, 2, \dots\}$ , $M \in \{0, 1, \dots, N\}$ , $n \in \{1, 2, \dots, N\}$	$n \frac{M}{N}$	$n \frac{M}{N} \frac{N-M}{N} \frac{N-n}{N-1}$ $(N > 1)$
Poisson $Pois(\lambda)$	$\frac{\lambda^m}{m!} e^{-\lambda}$ $m \in \{0, 1, \dots\}$	$\lambda > 0$	$\lambda$	$\lambda$
Geometrisch $Geom(p)$	$p(1-p)^{m-1}$ $m \in \{1, 2, \dots\}$	$0 < p < 1$	$\frac{1}{p}$	$\frac{1-p}{p^2}$

§: Für  $n = 1$  nennt man die Binomialverteilung auch Bernoulliverteilung mit  $P(X = 1) = p = 1 - P(X = 0)$ ,  $E(X) = p$ ,  $Var(p) = p(1-p)$ .

## 4.2 Stetige Verteilungen

Verteilung	Wahrscheinlichkeitsdichte $f(x)$	Verteilungsfunktion $F(x)$	Parameter- raum	Erwartungs- wert $\mu = E(X)$	Varianz $\sigma^2 = E([X - \mu]^2)$
Gleich (Uniform)	$\frac{1}{b-a}, x \in [a, b]$	$\frac{x}{b-a}, x \in [a, b]$	$-\infty < a < b < \infty$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$
Exponential <i>Exp</i> ( $\lambda$ )	$\lambda e^{-\lambda x}, x \geq 0$	$1 - e^{-\lambda x}, x \geq 0$	$\lambda > 0$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$
Gamma	$\frac{\lambda^r}{\Gamma(r)} x^{r-1} e^{-\lambda x}, x \geq 0$	$\frac{\gamma(r, \lambda x)}{\Gamma(r)}, x \geq 0$	$\lambda > 0, r > 0$	$\frac{r}{\lambda}$	$\frac{r}{\lambda^2}$
Cauchy	$\frac{1}{\pi\beta\{1 + [(x-\alpha)/\beta]^2\}}$	$\frac{1}{\pi} \operatorname{atan}\left(\frac{x-\alpha}{\beta}\right) + \frac{1}{2}$	$\beta > 0, \alpha \in \mathbb{R}$	-	-
Laplace	$\frac{\lambda}{2} e^{-\lambda x-\mu }$	$\begin{cases} \frac{1}{2} e^{\lambda(x-\mu)} & , x < \mu \\ 1 - \frac{1}{2} e^{-\lambda(x-\mu)} & , x \geq \mu \end{cases}$	$\lambda > 0, \mu \in \mathbb{R}$	$\mu$	$\frac{2}{\lambda^2}$

- Gamma-Funktion  $\Gamma(x)$ :  $\Gamma(x) = \int_0^\infty t^{x-1} e^{-t} dt$  mit  $\Gamma(x+1) = x\Gamma(x)$ ,  $\Gamma(n) = (n-1)!$  für  $n \in \mathbb{N}$ ,  $\Gamma(0.5) = \sqrt{\pi}$ .
- unvollständige Gamma-Funktion der oberen Grenze  $\gamma(x, s)$ :  $\gamma(x, s) = \int_0^s t^{x-1} e^{-t} dt$  ... eher von anekdotischem Interesse.

## 4.2 Stetige Verteilungen II

Verteilung	Wahrscheinlichkeitsdichte $f(x)$	Parameter-raum	Erwartungs-wert	Varianz
			$\mu = E(X)$	$\sigma^2 = E([X - \mu]^2)$
Normal $\mathcal{N}(\mu, \sigma^2)$	$\frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, x \in \mathbb{R}$	$\mu \in \mathbb{R}, \sigma > 0$	$\mu$	$\sigma^2$
$\chi_n^2$ *	$\frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} e^{-\frac{x}{2}}, x \geq 0$	$n \in \{1, 2, \dots\}$	$n$	$2n$
Student** $t_n$	$\frac{\Gamma(\frac{n+1}{2}) \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}}{\Gamma(\frac{n}{2}) \sqrt{\pi n}}, x \in \mathbb{R}$	$n \in \{1, 2, \dots\}$	$0 \quad (n > 1)$	$\frac{n}{n-2} \quad (n > 2)$
Fisher*** $F_{m,n}$	$\frac{\Gamma(\frac{m+n}{2}) \left(\frac{m}{n}\right)^{\frac{m}{2}}}{\Gamma(\frac{m}{2}) \Gamma(\frac{n}{2})} x^{\frac{m}{2}-1} \left(1 + \frac{m}{n} x\right)^{-\frac{m+n}{2}}, x \geq 0$	$m, n \in \{1, 2, \dots\}$	$\frac{n}{n-2} \quad (n > 2)$	$\frac{2n^2(m+n-2)}{m(n-2)^2(n-4)} \quad (n > 4)$

\*:  $\sum_{i=1}^n X_i^2 \sim \chi_n^2$  mit unabhängigen  $X_i \sim \mathcal{N}(0, 1), i = 1, 2, \dots, n$  — äquivalent zur Gamma-Verteilung  $\Gamma(1/2, n)$ .

\*\* :  $X / (\sqrt{Y/n}) \sim t_n$  mit unabhängigen  $X \sim \mathcal{N}(0, 1)$  und  $Y \sim \chi_n^2$

\*\*\*:  $(X/m) / (Y/n) \sim F_{m,n}$  mit unabhängigen  $X \sim \chi_m^2$  und  $Y \sim \chi_n^2$

- $\Gamma(\cdot)$ : Siehe Seite 42.

### 4.3 Übersicht Konfidenzintervalle

Verteilung, Voraussetzungen	$\vartheta$	$\hat{\vartheta}$	Konfidenzintervall
$n$ groß	$\mu$	$\bar{X}$	$\bar{X} - \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2} < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2}$ (oder $S$ statt $\sigma$ bei unbekanntem $\sigma^2$ )
$B(1, p)$ , $n\hat{p}(1-\hat{p}) > 9$	$p$	$\hat{p} = \bar{X}$	$\hat{p} - \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} z_{1-\alpha/2} < p < \hat{p} + \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} z_{1-\alpha/2}$
$B(1, p)$ , $n\hat{p}(1-\hat{p}) > 5$	$p$	$\hat{p} = \bar{X}$	$\frac{n \left[ \hat{p} + \frac{1}{2n} z_{1-\alpha/2}^2 - B \right]}{n + z_{1-\alpha/2}^2} < p < \frac{n \left[ \hat{p} + \frac{1}{2n} z_{1-\alpha/2}^2 + B \right]}{n + z_{1-\alpha/2}^2}$ mit $B = z_{1-\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n} + \left( \frac{1}{2n} z_{1-\alpha/2} \right)^2}$
$\mathcal{N}(\mu, \sigma^2)$ , $\sigma^2$ bekannt	$\mu$	$\bar{X}$	$\bar{X} - \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2} < \mu < \bar{X} + \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2}$
$\mathcal{N}(\mu, \sigma^2)$ , $\sigma^2$ unbekannt	$\mu$	$\bar{X}$	$\bar{X} - \frac{S}{\sqrt{n}} t_{n-1; 1-\alpha/2} < \mu < \bar{X} + \frac{S}{\sqrt{n}} t_{n-1; 1-\alpha/2}$
$\mathcal{N}(\mu, \sigma^2)$ , $\mu$ bekannt	$\sigma^2$	$\hat{S}^2$	$\frac{n\hat{S}^2}{\chi_{n; 1-\alpha/2}^2} < \sigma^2 < \frac{n\hat{S}^2}{\chi_{n; \alpha/2}^2}$ , $\hat{S}^2 = 1/n \sum_{i=1}^n (X_i - \mu)^2$
$\mathcal{N}(\mu, \sigma^2)$ , $\mu$ unbekannt	$\sigma^2$	$S^2$	$\frac{(n-1)S^2}{\chi_{n-1; 1-\alpha/2}^2} < \sigma^2 < \frac{(n-1)S^2}{\chi_{n-1; \alpha/2}^2}$ , $S^2 = 1/(n-1) \sum_{i=1}^n (X_i - \bar{X})^2$
$\mathcal{N} \left( \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix}, \begin{bmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{bmatrix} \right)$	$\rho$	$r$	$r - \frac{1-r^2}{\sqrt{n}} z_{1-\alpha/2} < \rho < r + \frac{1-r^2}{\sqrt{n}} z_{1-\alpha/2}$ , $r \hat{=}$ Korrelationskoeffizient nach Bravais-Pearson oder $\left[ \tanh \left( \tanh^{-1}(r) - \frac{z_{1-\alpha/2}}{\sqrt{n-3}} \right), \tanh \left( \tanh^{-1}(r) + \frac{z_{1-\alpha/2}}{\sqrt{n-3}} \right) \right]$ , Z-Transformation nach Fisher

## 4.4 Übersicht Einstichprobentests

Verteilung, Voraussetzungen	$H_0$	$H_1$	Prüfgröße $T$	Verteilung von $T$ unter $H_0$	kritische Werte, d. h. $H_0$ ablehnen, falls
<b>Normalverteilung</b>  $\sigma$ bekannt  $\sigma$ unbekannt	$\mu = \mu_0$	$\mu \neq \mu_0$	$\frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}}$	$\Phi$	$T \notin [-z_{1-\alpha/2}, z_{1-\alpha/2}]$
	$\mu \leq \mu_0$	$\mu > \mu_0$			$T > z_{1-\alpha}$
	$\mu \geq \mu_0$	$\mu < \mu_0$			$T < -z_{1-\alpha}$
	$\mu = \mu_0$	$\mu \neq \mu_0$	$\frac{\bar{X} - \mu_0}{S/\sqrt{n}}$	$t_{n-1}$ bzw. für $n > 30$ approx. $\Phi$	$T \notin [-t_{n-1;1-\alpha/2}, t_{n-1;1-\alpha/2}]$
	$\mu \leq \mu_0$	$\mu > \mu_0$			$T > t_{n-1;1-\alpha}$
	$\mu \geq \mu_0$	$\mu < \mu_0$			$T < -t_{n-1;1-\alpha}$
<b>beliebige Verteilung</b> mit Erwartungswert $\mu$	$\mu = \mu_0$	$\mu \neq \mu_0$	$\frac{\bar{X} - \mu_0}{S/\sqrt{n}}$	approx. $\Phi$	$T \notin [-z_{1-\alpha/2}, z_{1-\alpha/2}]$
	$\mu \leq \mu_0$	$\mu > \mu_0$			$T > z_{1-\alpha}$
	$\mu \geq \mu_0$	$\mu < \mu_0$			$T < -z_{1-\alpha}$
<b>Bernoulliverteilung</b> $n$ klein  $np_0(1-p_0) > 9$	$p = p_0$	$p \neq p_0$	Anzahl der Erfolge	$B(n, p_0)$	$T \notin [c_{\alpha/2}, c_{1-\alpha/2}]$
	$p \leq p_0$	$p > p_0$			$T > c_{1-\alpha}$
	$p \geq p_0$	$p < p_0$			$T < c_{\alpha} \dots c_{\alpha}$ ist das $\alpha$ -Quantil von $B(n, p_0)$
	$p = p_0$	$p \neq p_0$	$\frac{(\hat{p} - p_0)}{\sqrt{p_0(1-p_0)/n}}$	approx. $\Phi$	$T \notin [-z_{1-\alpha/2}, z_{1-\alpha/2}]$
	$p \leq p_0$	$p > p_0$			$T > z_{1-\alpha}$
	$p \geq p_0$	$p < p_0$			$T < -z_{1-\alpha}$
<b>Normalverteilung</b>	$\sigma^2 = \sigma_0^2$	$\sigma^2 \neq \sigma_0^2$	$(n-1)S^2/\sigma_0^2$  $(n\hat{S}^2/\sigma_0^2)^*$	$\chi_{n-1}^2$  $(\chi_n^2)^*$	$T \notin [\chi_{n-1;\alpha/2}^2, \chi_{n-1;1-\alpha/2}^2]$
	$\sigma^2 \leq \sigma_0^2$	$\sigma^2 > \sigma_0^2$			$T > \chi_{n-1;1-\alpha}^2$
	$\sigma^2 \geq \sigma_0^2$	$\sigma^2 < \sigma_0^2$			$T < \chi_{n-1;\alpha}^2$ <span style="float: right;">(<math>n</math> statt <math>n-1</math>)*</span>

\*: bei bekanntem Erwartungswert  $\mu$ ,  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ ,  $\hat{S}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$

## 4.5 Übersicht Zweistichprobentests

Verteilung, Voraussetzungen	$H_0$	$H_1$	Prüfgröße $T$	Verteilung von $T$ unter $H_0$	kritische Werte, d. h. $H_0$ ablehnen, falls
<b>Normalverteilung</b> $\sigma_X$ und $\sigma_Y$ bekannt	$\mu_X = \mu_Y$ $\mu_X \leq \mu_Y$ $\mu_X \geq \mu_Y$	$\mu_X \neq \mu_Y$ $\mu_X > \mu_Y$ $\mu_X < \mu_Y$	$(\bar{X} - \bar{Y}) / \sqrt{\frac{\sigma_X^2}{n_X} + \frac{\sigma_Y^2}{n_Y}}$	$\Phi$	$T \notin [-z_{1-\alpha/2}, z_{1-\alpha/2}]$ $T > z_{1-\alpha}$ $T < -z_{1-\alpha}$
$\sigma_X$ und $\sigma_Y$ unbekannt $\sigma_X = \sigma_Y$ , Stichproben klein	$\mu_X = \mu_Y$ $\mu_X \leq \mu_Y$ $\mu_X \geq \mu_Y$	$\mu_X \neq \mu_Y$ $\mu_X > \mu_Y$ $\mu_X < \mu_Y$	$(\bar{X} - \bar{Y}) / \sqrt{\hat{\sigma}^2 \left( \frac{1}{n_X} + \frac{1}{n_Y} \right)}$ mit $\hat{\sigma}^2 = \frac{n_X-1}{n_X+n_Y-2} S_X^2 + \frac{n_Y-1}{n_X+n_Y-2} S_Y^2$	$t_{n_X+n_Y-2}$	$T \notin [-t_{n_X+n_Y-2; 1-\alpha/2}, t_{n_X+n_Y-2; 1-\alpha/2}]$ $T > t_{n_X+n_Y-2; 1-\alpha}$ $T < -t_{n_X+n_Y-2; 1-\alpha}$
$\sigma_X$ und $\sigma_Y$ unbekannt $\sigma_X \neq \sigma_Y$ , Stichproben klein	$\mu_X = \mu_Y$ $\mu_X \leq \mu_Y$ $\mu_X \geq \mu_Y$	$\mu_X \neq \mu_Y$ $\mu_X > \mu_Y$ $\mu_X < \mu_Y$	$(\bar{X} - \bar{Y}) / \sqrt{\frac{S_X^2}{n_X} + \frac{S_Y^2}{n_Y}}$	$t_m$ , $m = \frac{(1+R)^2}{R^2/(n_X-1)+1/(n_Y-1)}$ , $R = \frac{n_Y S_X^2}{n_X S_Y^2}$	$T \notin [-t_{m; 1-\alpha/2}, t_{m; 1-\alpha/2}]$ $T > t_{m; 1-\alpha}$ $T < -t_{m; 1-\alpha}$
<b>Beliebige Verteilungen</b> mit $\sigma_X, \sigma_Y$ unbekannt, Stichproben groß ( $n_X, n_Y > 30$ )	$\mu_X = \mu_Y$ $\mu_X \leq \mu_Y$ $\mu_X \geq \mu_Y$	$\mu_X \neq \mu_Y$ $\mu_X > \mu_Y$ $\mu_X < \mu_Y$	$(\bar{X} - \bar{Y}) / \sqrt{\frac{S_X^2}{n_X} + \frac{S_Y^2}{n_Y}}$	$\Phi$	$T \notin [-z_{1-\alpha/2}, z_{1-\alpha/2}]$ $T > z_{1-\alpha}$ $T < -z_{1-\alpha}$
<b>Bernoulliverteilung</b> Stichproben groß ( $n_X, n_Y > 30$ )	$p_X = p_Y$ $p_X \leq p_Y$ $p_X \geq p_Y$	$p_X \neq p_Y$ $p_X > p_Y$ $p_X < p_Y$	$(\hat{p}_X - \hat{p}_Y) / \sqrt{\hat{p}(1-\hat{p}) \left( \frac{1}{n_X} + \frac{1}{n_Y} \right)}$ mit $\hat{p} = \frac{n_X \hat{p}_X + n_Y \hat{p}_Y}{n_X + n_Y}$	$\Phi$	$T \notin [-z_{1-\alpha/2}, z_{1-\alpha/2}]$ $T > z_{1-\alpha}$ $T < -z_{1-\alpha}$
<b>Normalverteilung</b>	$\sigma_X^2 = \sigma_Y^2$ $\sigma_X^2 \leq \sigma_Y^2$ $\sigma_X^2 \geq \sigma_Y^2$	$\sigma_X^2 \neq \sigma_Y^2$ $\sigma_X^2 > \sigma_Y^2$ $\sigma_X^2 < \sigma_Y^2$	$\frac{S_X^2}{S_Y^2}$	$F_{n_X-1, n_Y-1}$	$T \notin [1/F_{n_Y-1, n_X-1; 1-\alpha/2}, F_{n_X-1, n_Y-1; 1-\alpha/2}]$ $T > F_{n_X-1, n_Y-1; 1-\alpha}$ $T < 1/F_{n_Y-1, n_X-1; 1-\alpha}$

- $S_X^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  usw. – es wird also stets die Stichprobenvarianz benutzt.
- Siehe auch Seite 31 für sogenannte Nichtstandardhypothesen (z. B.  $H_0: \mu_X - \mu_Y = \Delta$ ).

## 4.6 Verteilungsfunktion der Standardnormalverteilung

$$X \sim \mathcal{N}(0,1)$$

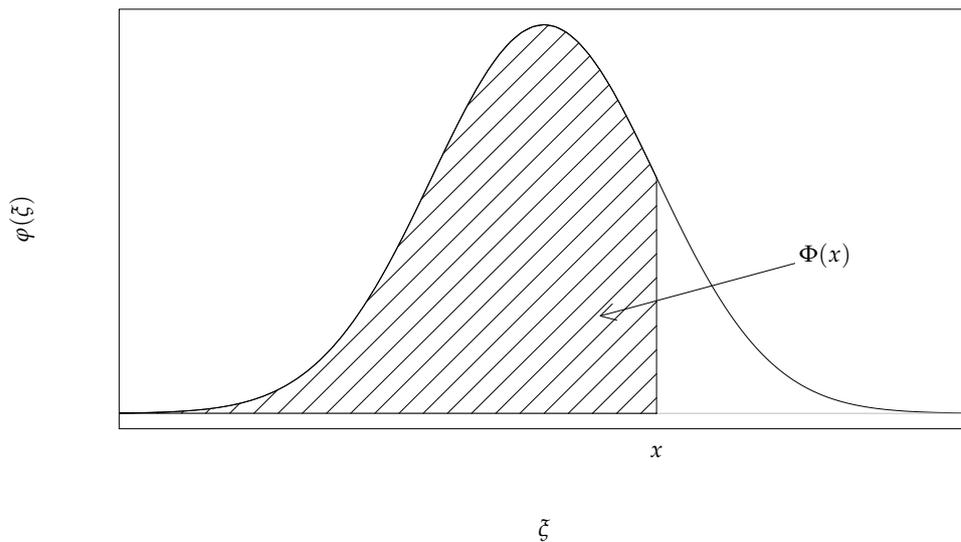
$$P(X \leq x) = \Phi(x) = \int_{-\infty}^x \overbrace{\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{\xi^2}{2}\right)}^{\varphi(\xi)} d\xi,$$

$$Y \sim \mathcal{N}(\mu, \sigma^2) \Rightarrow \frac{Y - \mu}{\sigma} \sim \mathcal{N}(0,1),$$

$$X \sim \mathcal{N}(0,1) \Rightarrow \mu + \sigma X \sim \mathcal{N}(\mu, \sigma^2).$$

Rechenregel für negative  $x$ :

$$\Phi(x) = 1 - \Phi(-x)$$



**Beispiele:**

$$\Phi(1.3) = 0.9032,$$

$$\Phi(2.64) = 0.9959,$$

$$\Phi(-0.83) = 1 - \Phi(0.83) = 1 - 0.7967 = 0.2033.$$

Ab  $x \geq 3.9$  ist  $\Phi(x) \approx 1$  bzw.  $x \leq -3.9$  ist  $\Phi(x) \approx 0$ .

	Excel	SPSS	STATA
<code>pnorm(x)</code>	<code>NORMVERT(x; 0; 1; WAHR)</code>	<code>CDF.NORMAL(x, 0, 1)</code>	<code>normal(x)</code>

#### 4 Appendix

$x$	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	0.5000	0.5040	0.5080	0.5120	0.5160	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5753
0.2	0.5793	0.5832	0.5871	0.5910	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.6480	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.6700	0.6736	0.6772	0.6808	0.6844	0.6879
0.5	0.6915	0.6950	0.6985	0.7019	0.7054	0.7088	0.7123	0.7157	0.7190	0.7224
0.6	0.7257	0.7291	0.7324	0.7357	0.7389	0.7422	0.7454	0.7486	0.7517	0.7549
0.7	0.7580	0.7611	0.7642	0.7673	0.7704	0.7734	0.7764	0.7794	0.7823	0.7852
0.8	0.7881	0.7910	0.7939	0.7967	0.7995	0.8023	0.8051	0.8078	0.8106	0.8133
0.9	0.8159	0.8186	0.8212	0.8238	0.8264	0.8289	0.8315	0.8340	0.8365	0.8389
1.0	0.8413	0.8438	0.8461	0.8485	0.8508	0.8531	0.8554	0.8577	0.8599	0.8621
1.1	0.8643	0.8665	0.8686	0.8708	0.8729	0.8749	0.8770	0.8790	0.8810	0.8830
1.2	0.8849	0.8869	0.8888	0.8907	0.8925	0.8944	0.8962	0.8980	0.8997	0.9015
1.3	0.9032	0.9049	0.9066	0.9082	0.9099	0.9115	0.9131	0.9147	0.9162	0.9177
1.4	0.9192	0.9207	0.9222	0.9236	0.9251	0.9265	0.9279	0.9292	0.9306	0.9319
1.5	0.9332	0.9345	0.9357	0.9370	0.9382	0.9394	0.9406	0.9418	0.9429	0.9441
1.6	0.9452	0.9463	0.9474	0.9484	0.9495	0.9505	0.9515	0.9525	0.9535	0.9545
1.7	0.9554	0.9564	0.9573	0.9582	0.9591	0.9599	0.9608	0.9616	0.9625	0.9633
1.8	0.9641	0.9649	0.9656	0.9664	0.9671	0.9678	0.9686	0.9693	0.9699	0.9706
1.9	0.9713	0.9719	0.9726	0.9732	0.9738	0.9744	0.9750	0.9756	0.9761	0.9767
2.0	0.9772	0.9778	0.9783	0.9788	0.9793	0.9798	0.9803	0.9808	0.9812	0.9817
2.1	0.9821	0.9826	0.9830	0.9834	0.9838	0.9842	0.9846	0.9850	0.9854	0.9857
2.2	0.9861	0.9864	0.9868	0.9871	0.9875	0.9878	0.9881	0.9884	0.9887	0.9890
2.3	0.9893	0.9896	0.9898	0.9901	0.9904	0.9906	0.9909	0.9911	0.9913	0.9916
2.4	0.9918	0.9920	0.9922	0.9925	0.9927	0.9929	0.9931	0.9932	0.9934	0.9936
2.5	0.9938	0.9940	0.9941	0.9943	0.9945	0.9946	0.9948	0.9949	0.9951	0.9952
2.6	0.9953	0.9955	0.9956	0.9957	0.9959	0.9960	0.9961	0.9962	0.9963	0.9964
2.7	0.9965	0.9966	0.9967	0.9968	0.9969	0.9970	0.9971	0.9972	0.9973	0.9974
2.8	0.9974	0.9975	0.9976	0.9977	0.9977	0.9978	0.9979	0.9979	0.9980	0.9981
2.9	0.9981	0.9982	0.9982	0.9983	0.9984	0.9984	0.9985	0.9985	0.9986	0.9986
3.0	0.9987	0.9987	0.9987	0.9988	0.9988	0.9989	0.9989	0.9989	0.9990	0.9990
3.1	0.9990	0.9991	0.9991	0.9991	0.9992	0.9992	0.9992	0.9992	0.9993	0.9993
3.2	0.9993	0.9993	0.9994	0.9994	0.9994	0.9994	0.9994	0.9995	0.9995	0.9995
3.3	0.9995	0.9995	0.9995	0.9996	0.9996	0.9996	0.9996	0.9996	0.9996	0.9997
3.4	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9998
3.5	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998
3.6	0.9998	0.9998	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.7	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.8	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000

	Excel	SPSS	STATA
<code>pnorm(x)</code>	<code>NORMVERT(x; 0; 1; WAHR)</code>	<code>CDF.NORMAL(x, 0, 1)</code>	<code>normal(x)</code>

## 4.7 Quantile der Standardnormalverteilung

$$X \sim \mathcal{N}(0, 1) : z_\alpha = \Phi^{-1}(\alpha) \Leftrightarrow \alpha = \Phi(z_\alpha) = \int_{-\infty}^{z_\alpha} \overbrace{\frac{1}{\sqrt{2\pi}} \exp\left(\frac{-x^2}{2}\right)}^{\varphi(x)} dx,$$

$$Y \sim \mathcal{N}(\mu, \sigma^2) : y_\alpha = \mu + \sigma z_\alpha \rightsquigarrow P(Y \leq y_\alpha) = \alpha.$$

Rechenregel für  $\alpha < 0.5$ :

$$z_\alpha = -z_{1-\alpha}$$

$\alpha$	$z_\alpha$	$\alpha$	$z_\alpha$	$\alpha$	$z_\alpha$	$\alpha$	$z_\alpha$
0.9999	3.7190	<b>0.9975</b>	<b>2.8070</b>	0.965	1.8119	0.83	0.9542
0.9998	3.5401	0.9970	2.7478	0.960	1.7507	0.82	0.9154
0.9997	3.4316	0.9965	2.6968	0.955	1.6954	0.81	0.8779
0.9996	3.3528	0.9960	2.6521	<b>0.950</b>	<b>1.6449</b>	0.80	0.8416
<b>0.9995</b>	<b>3.2905</b>	0.9955	2.6121	0.945	1.5982	0.79	0.8064
0.9994	3.2389	<b>0.9950</b>	<b>2.5758</b>	0.940	1.5548	0.78	0.7722
0.9993	3.1947	0.9945	2.5427	0.935	1.5141	0.76	0.7063
0.9992	3.1559	0.9940	2.5121	0.930	1.4758	0.74	0.6433
0.9991	3.1214	0.9935	2.4838	0.925	1.4395	0.72	0.5828
<b>0.9990</b>	<b>3.0902</b>	0.9930	2.4573	0.920	1.4051	0.70	0.5244
0.9989	3.0618	0.9925	2.4324	0.915	1.3722	0.68	0.4677
0.9988	3.0357	0.9920	2.4089	0.910	1.3408	0.66	0.4125
0.9987	3.0115	0.9915	2.3867	0.905	1.3106	0.64	0.3585
0.9986	2.9889	0.9910	2.3656	<b>0.900</b>	<b>1.2816</b>	0.62	0.3055
0.9985	2.9677	0.9905	2.3455	0.890	1.2265	0.60	0.2533
0.9984	2.9478	<b>0.9900</b>	<b>2.3263</b>	0.880	1.1750	0.58	0.2019
0.9983	2.9290	0.9850	2.1701	0.870	1.1264	0.56	0.1510
0.9982	2.9112	0.9800	2.0537	0.860	1.0803	0.54	0.1004
0.9981	2.8943	<b>0.9750</b>	<b>1.9600</b>	0.850	1.0364	0.52	0.0502
0.9980	2.8782	0.9700	1.8808	0.840	0.9945	0.50	0.0000

	Excel	SPSS	STATA
qnorm(alpha)	NORMINV(alpha; 0; 1)	IDF.NORMAL(alpha, 0, 1)	invnorm(alpha)

4.8 Quantile der  $t$ -Verteilung

$$t_{n;\alpha} = F_{t_n}^{-1}(\alpha) \Leftrightarrow \alpha = F_{t_n}(t_{n;\alpha}) = \int_{-\infty}^{t_{n;\alpha}} f_n(\tau) d\tau, \quad f_n(\tau) = \frac{\Gamma\left(\frac{n+1}{2}\right) \left(1 + \frac{\tau^2}{n}\right)^{-\frac{n+1}{2}}}{\Gamma\left(\frac{n}{2}\right) \sqrt{\pi n}}$$

Rechenregel für  $\alpha < 0.5$ :

$$t_{n;\alpha} = -t_{n;1-\alpha}$$

$n$	$\alpha$							
	0.9	0.95	0.975	0.99	0.995	0.9975	0.999	0.9995
1	3.078	6.314	12.71	31.82	63.66	127.3	318.3	636.6
2	1.886	2.920	4.303	6.965	9.925	14.09	22.33	31.60
3	1.638	2.353	3.182	4.541	5.841	7.453	10.22	12.92
4	1.533	2.132	2.776	3.747	4.604	5.598	7.173	8.610
5	1.476	2.015	2.571	3.365	4.032	4.773	5.893	6.869
6	1.440	1.943	2.447	3.143	3.707	4.317	5.208	5.959
7	1.415	1.895	2.365	2.998	3.499	4.029	4.785	5.408
8	1.397	1.860	2.306	2.896	3.355	3.833	4.501	5.041
9	1.383	1.833	2.262	2.821	3.250	3.690	4.297	4.781
10	1.372	1.812	2.228	2.764	3.169	3.581	4.144	4.587
11	1.363	1.796	2.201	2.718	3.106	3.497	4.025	4.437
12	1.356	1.782	2.179	2.681	3.055	3.428	3.930	4.318
13	1.350	1.771	2.160	2.650	3.012	3.372	3.852	4.221
14	1.345	1.761	2.145	2.624	2.977	3.326	3.787	4.140
15	1.341	1.753	2.131	2.602	2.947	3.286	3.733	4.073
16	1.337	1.746	2.120	2.583	2.921	3.252	3.686	4.015
17	1.333	1.740	2.110	2.567	2.898	3.222	3.646	3.965
18	1.330	1.734	2.101	2.552	2.878	3.197	3.610	3.922
19	1.328	1.729	2.093	2.539	2.861	3.174	3.579	3.883
20	1.325	1.725	2.086	2.528	2.845	3.153	3.552	3.850
21	1.323	1.721	2.080	2.518	2.831	3.135	3.527	3.819
22	1.321	1.717	2.074	2.508	2.819	3.119	3.505	3.792
23	1.319	1.714	2.069	2.500	2.807	3.104	3.485	3.768
24	1.318	1.711	2.064	2.492	2.797	3.091	3.467	3.745
25	1.316	1.708	2.060	2.485	2.787	3.078	3.450	3.725
26	1.315	1.706	2.056	2.479	2.779	3.067	3.435	3.707
27	1.314	1.703	2.052	2.473	2.771	3.057	3.421	3.690
28	1.313	1.701	2.048	2.467	2.763	3.047	3.408	3.674
29	1.311	1.699	2.045	2.462	2.756	3.038	3.396	3.659
30	1.310	1.697	2.042	2.457	2.750	3.030	3.385	3.646
40	1.303	1.684	2.021	2.423	2.704	2.971	3.307	3.551
50	1.299	1.676	2.009	2.403	2.678	2.937	3.261	3.496
60	1.296	1.671	2.000	2.390	2.660	2.915	3.232	3.460
70	1.294	1.667	1.994	2.381	2.648	2.899	3.211	3.435
80	1.292	1.664	1.990	2.374	2.639	2.887	3.195	3.416
90	1.291	1.662	1.987	2.368	2.632	2.878	3.183	3.402
100	1.290	1.660	1.984	2.364	2.626	2.871	3.174	3.390
500	1.283	1.648	1.965	2.334	2.586	2.820	3.107	3.310
$\infty$	1.282	1.645	1.960	2.326	2.576	2.807	3.090	3.291

Für große  $n > 30$  ist  $t_{n;\alpha} \approx \sqrt{\frac{n}{n-2}} z_\alpha$ ;  $z_\alpha$  ist das entsprechende Quantil der Standardnormalverteilung.

z. B. 40 | 1.315 1.688 2.011 2.387 2.643 2.880 3.171 3.376

	Excel	SPSS	STATA
qt(alpha, n)	TINV(2*(1-alpha); n)	IDF.T(alpha, n)	invttail(m, 1-alpha)

4.9 Quantile der  $\chi^2$ -Verteilung

$$\chi_{n;\alpha}^2 = F_{\chi_n^2}^{-1}(\alpha) \Leftrightarrow \alpha = F_{\chi_n^2}(\chi_{n;\alpha}^2) = \int_{-\infty}^{\chi_{n;\alpha}^2} f_n(c) dc, \quad f_n(c) = \frac{c^{\frac{n}{2}-1} e^{-c/2}}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})}$$

$$n = 1, 2, \dots, 50$$

n	$\alpha$									
	0.005	0.01	0.025	0.05	0.1	0.9	0.95	0.975	0.99	0.995
1	0.000	0.000	0.001	0.004	0.016	2.706	3.841	5.024	6.635	7.879
2	0.010	0.020	0.051	0.103	0.211	4.605	5.991	7.378	9.210	10.60
3	0.072	0.115	0.216	0.352	0.584	6.251	7.815	9.348	11.34	12.84
4	0.207	0.297	0.484	0.711	1.064	7.779	9.488	11.14	13.28	14.86
5	0.412	0.554	0.831	1.145	1.610	9.236	11.07	12.83	15.09	16.75
6	0.676	0.872	1.237	1.635	2.204	10.64	12.59	14.45	16.81	18.55
7	0.989	1.239	1.690	2.167	2.833	12.02	14.07	16.01	18.48	20.28
8	1.344	1.646	2.180	2.733	3.490	13.36	15.51	17.53	20.09	21.95
9	1.735	2.088	2.700	3.325	4.168	14.68	16.92	19.02	21.67	23.59
10	2.156	2.558	3.247	3.940	4.865	15.99	18.31	20.48	23.21	25.19
11	2.603	3.053	3.816	4.575	5.578	17.28	19.68	21.92	24.72	26.76
12	3.074	3.571	4.404	5.226	6.304	18.55	21.03	23.34	26.22	28.30
13	3.565	4.107	5.009	5.892	7.042	19.81	22.36	24.74	27.69	29.82
14	4.075	4.660	5.629	6.571	7.790	21.06	23.68	26.12	29.14	31.32
15	4.601	5.229	6.262	7.261	8.547	22.31	25.00	27.49	30.58	32.80
16	5.142	5.812	6.908	7.962	9.312	23.54	26.30	28.85	32.00	34.27
17	5.697	6.408	7.564	8.672	10.09	24.77	27.59	30.19	33.41	35.72
18	6.265	7.015	8.231	9.390	10.86	25.99	28.87	31.53	34.81	37.16
19	6.844	7.633	8.907	10.12	11.65	27.20	30.14	32.85	36.19	38.58
20	7.434	8.260	9.591	10.85	12.44	28.41	31.41	34.17	37.57	40.00
21	8.034	8.897	10.28	11.59	13.24	29.62	32.67	35.48	38.93	41.40
22	8.643	9.542	10.98	12.34	14.04	30.81	33.92	36.78	40.29	42.80
23	9.260	10.20	11.69	13.09	14.85	32.01	35.17	38.08	41.64	44.18
24	9.886	10.86	12.40	13.85	15.66	33.20	36.42	39.36	42.98	45.56
25	10.52	11.52	13.12	14.61	16.47	34.38	37.65	40.65	44.31	46.93
26	11.16	12.20	13.84	15.38	17.29	35.56	38.89	41.92	45.64	48.29
27	11.81	12.88	14.57	16.15	18.11	36.74	40.11	43.19	46.96	49.64
28	12.46	13.56	15.31	16.93	18.94	37.92	41.34	44.46	48.28	50.99
29	13.12	14.26	16.05	17.71	19.77	39.09	42.56	45.72	49.59	52.34
30	13.79	14.95	16.79	18.49	20.60	40.26	43.77	46.98	50.89	53.67
31	14.46	15.66	17.54	19.28	21.43	41.42	44.99	48.23	52.19	55.00
32	15.13	16.36	18.29	20.07	22.27	42.58	46.19	49.48	53.49	56.33
33	15.82	17.07	19.05	20.87	23.11	43.75	47.40	50.73	54.78	57.65
34	16.50	17.79	19.81	21.66	23.95	44.90	48.60	51.97	56.06	58.96
35	17.19	18.51	20.57	22.47	24.80	46.06	49.80	53.20	57.34	60.27
36	17.89	19.23	21.34	23.27	25.64	47.21	51.00	54.44	58.62	61.58
37	18.59	19.96	22.11	24.07	26.49	48.36	52.19	55.67	59.89	62.88
38	19.29	20.69	22.88	24.88	27.34	49.51	53.38	56.90	61.16	64.18
39	20.00	21.43	23.65	25.70	28.20	50.66	54.57	58.12	62.43	65.48
40	20.71	22.16	24.43	26.51	29.05	51.81	55.76	59.34	63.69	66.77
41	21.42	22.91	25.21	27.33	29.91	52.95	56.94	60.56	64.95	68.05
42	22.14	23.65	26.00	28.14	30.77	54.09	58.12	61.78	66.21	69.34
43	22.86	24.40	26.79	28.96	31.63	55.23	59.30	62.99	67.46	70.62
44	23.58	25.15	27.57	29.79	32.49	56.37	60.48	64.20	68.71	71.89
45	24.31	25.90	28.37	30.61	33.35	57.51	61.66	65.41	69.96	73.17
46	25.04	26.66	29.16	31.44	34.22	58.64	62.83	66.62	71.20	74.44
47	25.77	27.42	29.96	32.27	35.08	59.77	64.00	67.82	72.44	75.70
48	26.51	28.18	30.75	33.10	35.95	60.91	65.17	69.02	73.68	76.97
49	27.25	28.94	31.55	33.93	36.82	62.04	66.34	70.22	74.92	78.23
50	27.99	29.71	32.36	34.76	37.69	63.17	67.50	71.42	76.15	79.49

#### 4 Appendix

#### Quantile der $\chi^2$ -Verteilung – Fortsetzung

$n = 55, \dots, 1000$

$n$	$\alpha$									
	0.005	0.01	0.025	0.05	0.1	0.9	0.95	0.975	0.99	0.995
55	31.73	33.57	36.40	38.96	42.06	68.80	73.31	77.38	82.29	85.75
60	35.53	37.48	40.48	43.19	46.46	74.40	79.08	83.30	88.38	91.95
65	39.38	41.44	44.60	47.45	50.88	79.97	84.82	89.18	94.42	98.11
70	43.28	45.44	48.76	51.74	55.33	85.53	90.53	95.02	100.4	104.2
75	47.21	49.48	52.94	56.05	59.79	91.06	96.22	100.8	106.4	110.3
80	51.17	53.54	57.15	60.39	64.28	96.58	101.9	106.6	112.3	116.3
85	55.17	57.63	61.39	64.75	68.78	102.1	107.5	112.4	118.2	122.3
90	59.20	61.75	65.65	69.13	73.29	107.6	113.1	118.1	124.1	128.3
95	63.25	65.90	69.92	73.52	77.82	113.0	118.8	123.9	130.0	134.2
100	67.33	70.06	74.22	77.93	82.36	118.5	124.3	129.6	135.8	140.2
110	75.55	78.46	82.87	86.79	91.47	129.4	135.5	140.9	147.4	151.9
120	83.85	86.92	91.57	95.70	100.6	140.2	146.6	152.2	159.0	163.6
130	92.22	95.45	100.3	104.7	109.8	151.0	157.6	163.5	170.4	175.3
140	100.7	104.0	109.1	113.7	119.0	161.8	168.6	174.6	181.8	186.8
150	109.1	112.7	118.0	122.7	128.3	172.6	179.6	185.8	193.2	198.4
160	117.7	121.3	126.9	131.8	137.5	183.3	190.5	196.9	204.5	209.8
170	126.3	130.1	135.8	140.8	146.8	194.0	201.4	208.0	215.8	221.2
180	134.9	138.8	144.7	150.0	156.2	204.7	212.3	219.0	227.1	232.6
190	143.5	147.6	153.7	159.1	165.5	215.4	223.2	230.1	238.3	244.0
200	152.2	156.4	162.7	168.3	174.8	226.0	234.0	241.1	249.4	255.3
220	169.7	174.2	180.8	186.7	193.6	247.3	255.6	263.0	271.7	277.8
240	187.3	192.0	199.0	205.1	212.4	268.5	277.1	284.8	293.9	300.2
260	205.0	209.9	217.2	223.7	231.2	289.6	298.6	306.6	316.0	322.5
280	222.8	227.9	235.5	242.2	250.1	310.7	320.0	328.2	338.0	344.7
300	240.7	246.0	253.9	260.9	269.1	331.8	341.4	349.9	359.9	366.8
320	258.6	264.1	272.3	279.6	288.0	352.8	362.7	371.4	381.8	388.9
340	276.6	282.3	290.8	298.3	307.0	373.8	384.0	393.0	403.6	410.9
360	294.6	300.5	309.3	317.0	326.1	394.8	405.2	414.5	425.3	432.9
380	312.7	318.8	327.9	335.8	345.1	415.7	426.5	435.9	447.1	454.8
400	330.9	337.2	346.5	354.6	364.2	436.6	447.6	457.3	468.7	476.6
450	376.5	383.2	393.1	401.8	412.0	488.8	500.5	510.7	522.7	531.0
500	422.3	429.4	439.9	449.1	459.9	540.9	553.1	563.9	576.5	585.2
550	468.3	475.8	486.9	496.6	507.9	592.9	605.7	616.9	630.1	639.2
600	514.5	522.4	534.0	544.2	556.1	644.8	658.1	669.8	683.5	693.0
650	560.9	569.1	581.2	591.9	604.2	696.6	710.4	722.5	736.8	746.6
700	607.4	615.9	628.6	639.6	652.5	748.4	762.7	775.2	790.0	800.1
750	654.0	662.9	676.0	687.5	700.8	800.0	814.8	827.8	843.0	853.5
800	700.7	709.9	723.5	735.4	749.2	851.7	866.9	880.3	896.0	906.8
850	747.6	757.0	771.1	783.3	797.6	903.2	918.9	932.7	948.8	960.0
900	794.5	804.3	818.8	831.4	846.1	954.8	970.9	985.0	1002	1013
950	841.5	851.5	866.5	879.5	894.6	1006	1023	1037	1054	1066
1000	888.6	898.9	914.3	927.6	943.1	1058	1075	1090	1107	1119

Für große  $n > 50$  ist  $\chi_{n,\alpha}^2 \approx (z_\alpha + \sqrt{2n-1})^2/2$ ;  $z_\alpha$  – Quantil der Standardnormalverteilung.

z. B. 1000 | 887.7 | 898.2 | 913.8 | 927.3 | 943.0 | 1058 | 1074 | 1089 | 1106 | 1118

	Excel	SPSS	STATA
qchisq(alpha, n)	CHIINV(1-alpha; n)	IDF.CHISQ(alpha, n)	invchi2(m, alpha)

## 4.10 Quantile der F-Verteilung

$$F_{m,n;1-\alpha} = F_{F_{m,n}}^{-1}(1-\alpha) \Leftrightarrow 1-\alpha = F_{F_{m,n}}(F_{m,n;1-\alpha}) = \int_0^{F_{m,n;1-\alpha}} f(x) dx$$

$$\text{mit } f(x) = \frac{\Gamma\left(\frac{m+n}{2}\right) \left(\frac{m}{n}\right)^{m/2}}{\Gamma\left(\frac{m}{2}\right) \Gamma\left(\frac{n}{2}\right)} x^{m/2-1} \left(1 + \frac{m}{n}x\right)^{-(m+n)/2}$$

Bezeichnung:

$m$  – Anzahl der Freiheitsgrade im Zähler,  $n$  – Anzahl der Freiheitsgrade im Nenner

Rechenregel zum Ermittlung von Quantilen kleiner Ordnung ( $\alpha < 0.5$ ):

$$F_{m,n;\alpha} = \frac{1}{F_{n,m;1-\alpha}}$$

Auf den nächsten vier Seiten folgen die Quantile für

- $\alpha \in \{0.9, 0.95, 0.975, 0.99\}$  und
- $n, m \in \{1, 2, \dots, 10, 15, 20, 30, \dots, 100\}$ .

	Excel	SPSS	STATA
qf(alpha, m, n)	FINV(1-alpha; m; n)	IDF.F(alpha, m, n)	invF(m, n, alpha)

Quantile der  $F$ -Verteilung  $F_{m,n;\alpha}$  mit  $\alpha = 0.9$ 

$m$	$n$																			
	1	2	3	4	5	6	7	8	9	10	15	20	30	40	50	60	70	80	90	100
1	39.86	8.526	5.538	4.545	4.060	3.776	3.589	3.458	3.360	3.285	3.073	2.975	2.881	2.835	2.809	2.791	2.779	2.769	2.762	2.756
2	49.50	9.000	5.462	4.325	3.780	3.463	3.257	3.113	3.006	2.924	2.695	2.589	2.489	2.440	2.412	2.393	2.380	2.370	2.363	2.356
3	53.59	9.162	5.391	4.191	3.619	3.289	3.074	2.924	2.813	2.728	2.490	2.380	2.276	2.226	2.197	2.177	2.164	2.154	2.146	2.139
4	55.83	9.243	5.343	4.107	3.520	3.181	2.961	2.806	2.693	2.605	2.361	2.249	2.142	2.091	2.061	2.041	2.027	2.016	2.008	2.002
5	57.24	9.293	5.309	4.051	3.453	3.108	2.883	2.726	2.611	2.522	2.273	2.158	2.049	1.997	1.966	1.946	1.931	1.921	1.912	1.906
6	58.20	9.326	5.285	4.010	3.405	3.055	2.827	2.668	2.551	2.461	2.208	2.091	1.980	1.927	1.895	1.875	1.860	1.849	1.841	1.834
7	58.91	9.349	5.266	3.979	3.368	3.014	2.785	2.624	2.505	2.414	2.158	2.040	1.927	1.873	1.840	1.819	1.804	1.793	1.785	1.778
8	59.44	9.367	5.252	3.955	3.339	2.983	2.752	2.589	2.469	2.377	2.119	1.999	1.884	1.829	1.796	1.775	1.760	1.748	1.739	1.732
9	59.86	9.381	5.240	3.936	3.316	2.958	2.725	2.561	2.440	2.347	2.086	1.965	1.849	1.793	1.760	1.738	1.723	1.711	1.702	1.695
10	60.20	9.392	5.230	3.920	3.297	2.937	2.703	2.538	2.416	2.323	2.059	1.937	1.819	1.763	1.729	1.707	1.691	1.680	1.670	1.663
15	61.22	9.425	5.200	3.870	3.238	2.871	2.632	2.464	2.340	2.244	1.972	1.845	1.722	1.662	1.627	1.603	1.587	1.574	1.564	1.557
20	61.74	9.441	5.184	3.844	3.207	2.836	2.595	2.425	2.298	2.201	1.924	1.794	1.667	1.605	1.568	1.543	1.526	1.513	1.503	1.494
30	62.26	9.458	5.168	3.817	3.174	2.800	2.555	2.383	2.255	2.155	1.873	1.738	1.606	1.541	1.502	1.476	1.457	1.443	1.432	1.423
40	62.53	9.466	5.160	3.804	3.157	2.781	2.535	2.361	2.232	2.132	1.845	1.708	1.573	1.506	1.465	1.437	1.418	1.403	1.391	1.382
50	62.69	9.471	5.155	3.795	3.147	2.770	2.523	2.348	2.218	2.117	1.828	1.690	1.552	1.483	1.441	1.413	1.392	1.377	1.365	1.355
60	62.79	9.475	5.151	3.790	3.140	2.762	2.514	2.339	2.208	2.107	1.817	1.677	1.538	1.467	1.424	1.395	1.374	1.358	1.346	1.336
70	62.87	9.477	5.149	3.786	3.135	2.756	2.508	2.333	2.202	2.100	1.808	1.667	1.527	1.455	1.412	1.382	1.361	1.344	1.332	1.321
80	62.93	9.479	5.147	3.782	3.132	2.752	2.504	2.328	2.196	2.095	1.802	1.660	1.519	1.447	1.402	1.372	1.350	1.334	1.321	1.310
90	62.97	9.480	5.145	3.780	3.129	2.749	2.500	2.324	2.192	2.090	1.797	1.655	1.512	1.439	1.395	1.364	1.342	1.325	1.312	1.301
100	63.01	9.481	5.144	3.778	3.126	2.746	2.497	2.321	2.189	2.087	1.793	1.650	1.507	1.434	1.388	1.358	1.335	1.318	1.304	1.293

Quantile der  $F$ -Verteilung  $F_{m,n,\alpha}$  mit  $\alpha = 0.95$

$m$	$n$																			
	1	2	3	4	5	6	7	8	9	10	15	20	30	40	50	60	70	80	90	100
1	161.4	18.51	10.13	7.709	6.608	5.987	5.591	5.318	5.117	4.965	4.543	4.351	4.171	4.085	4.034	4.001	3.978	3.960	3.947	3.936
2	200.0	19.00	9.552	6.944	5.786	5.143	4.737	4.459	4.256	4.103	3.682	3.493	3.316	3.232	3.183	3.150	3.128	3.111	3.098	3.087
3	215.7	19.16	9.277	6.591	5.409	4.757	4.347	4.066	3.863	3.708	3.287	3.098	2.922	2.839	2.790	2.758	2.736	2.719	2.706	2.696
4	224.6	19.25	9.117	6.388	5.192	4.534	4.120	3.838	3.633	3.478	3.056	2.866	2.690	2.606	2.557	2.525	2.503	2.486	2.473	2.463
5	230.2	19.30	9.013	6.256	5.050	4.387	3.972	3.687	3.482	3.326	2.901	2.711	2.534	2.449	2.400	2.368	2.346	2.329	2.316	2.305
6	234.0	19.33	8.941	6.163	4.950	4.284	3.866	3.581	3.374	3.217	2.790	2.599	2.421	2.336	2.286	2.254	2.231	2.214	2.201	2.191
7	236.8	19.35	8.887	6.094	4.876	4.207	3.787	3.500	3.293	3.135	2.707	2.514	2.334	2.249	2.199	2.167	2.143	2.126	2.113	2.103
8	238.9	19.37	8.845	6.041	4.818	4.147	3.726	3.438	3.230	3.072	2.641	2.447	2.266	2.180	2.130	2.097	2.074	2.056	2.043	2.032
9	240.5	19.38	8.812	5.999	4.772	4.099	3.677	3.388	3.179	3.020	2.588	2.393	2.211	2.124	2.073	2.040	2.017	1.999	1.986	1.975
10	241.9	19.40	8.786	5.964	4.735	4.060	3.637	3.347	3.137	2.978	2.544	2.348	2.165	2.077	2.026	1.993	1.969	1.951	1.938	1.927
15	246.0	19.43	8.703	5.858	4.619	3.938	3.511	3.218	3.006	2.845	2.403	2.203	2.015	1.924	1.871	1.836	1.812	1.793	1.779	1.768
20	248.0	19.45	8.660	5.803	4.558	3.874	3.445	3.150	2.936	2.774	2.328	2.124	1.932	1.839	1.784	1.748	1.722	1.703	1.688	1.676
30	250.1	19.46	8.617	5.746	4.496	3.808	3.376	3.079	2.864	2.700	2.247	2.039	1.841	1.744	1.687	1.649	1.622	1.602	1.586	1.573
40	251.1	19.47	8.594	5.717	4.464	3.774	3.340	3.043	2.826	2.661	2.204	1.994	1.792	1.693	1.634	1.594	1.566	1.545	1.528	1.515
50	251.8	19.48	8.581	5.699	4.444	3.754	3.319	3.020	2.803	2.637	2.178	1.966	1.761	1.660	1.599	1.559	1.530	1.508	1.491	1.477
60	252.2	19.48	8.572	5.688	4.431	3.740	3.304	3.005	2.787	2.621	2.160	1.946	1.740	1.637	1.576	1.534	1.505	1.482	1.465	1.45
70	252.5	19.48	8.566	5.679	4.422	3.730	3.294	2.994	2.776	2.610	2.147	1.932	1.724	1.621	1.558	1.516	1.486	1.463	1.445	1.430
80	252.7	19.48	8.561	5.673	4.415	3.722	3.286	2.986	2.768	2.601	2.137	1.922	1.712	1.608	1.544	1.502	1.471	1.448	1.429	1.415
90	252.9	19.48	8.557	5.668	4.409	3.716	3.280	2.980	2.761	2.594	2.130	1.913	1.703	1.597	1.534	1.491	1.459	1.436	1.417	1.402
100	253.0	19.49	8.554	5.664	4.405	3.712	3.275	2.975	2.756	2.588	2.123	1.907	1.695	1.589	1.525	1.481	1.450	1.426	1.407	1.392

Quantile der  $F$ -Verteilung  $F_{m,n;\alpha}$  mit  $\alpha = 0.975$ 

$m$	$n$																			
	1	2	3	4	5	6	7	8	9	10	15	20	30	40	50	60	70	80	90	100
1	647.8	38.51	17.44	12.22	10.01	8.813	8.073	7.571	7.209	6.937	6.200	5.871	5.568	5.424	5.340	5.286	5.247	5.218	5.196	5.179
2	799.5	39.00	16.04	10.65	8.434	7.260	6.542	6.059	5.715	5.456	4.765	4.461	4.182	4.051	3.975	3.925	3.890	3.864	3.844	3.828
3	864.2	39.16	15.44	9.979	7.764	6.599	5.890	5.416	5.078	4.826	4.153	3.859	3.589	3.463	3.390	3.343	3.309	3.284	3.265	3.250
4	899.6	39.25	15.10	9.605	7.388	6.227	5.523	5.053	4.718	4.468	3.804	3.515	3.250	3.126	3.054	3.008	2.975	2.950	2.932	2.917
5	921.8	39.30	14.88	9.364	7.146	5.988	5.285	4.817	4.484	4.236	3.576	3.289	3.026	2.904	2.833	2.786	2.754	2.730	2.711	2.696
6	937.1	39.33	14.74	9.197	6.978	5.820	5.119	4.652	4.320	4.072	3.415	3.128	2.867	2.744	2.674	2.627	2.595	2.571	2.552	2.537
7	948.2	39.36	14.62	9.074	6.853	5.695	4.995	4.529	4.197	3.950	3.293	3.007	2.746	2.624	2.553	2.507	2.474	2.450	2.432	2.417
8	956.7	39.37	14.54	8.980	6.757	5.600	4.899	4.433	4.102	3.855	3.199	2.913	2.651	2.529	2.458	2.412	2.379	2.355	2.336	2.321
9	963.3	39.39	14.47	8.905	6.681	5.523	4.823	4.357	4.026	3.779	3.123	2.837	2.575	2.452	2.381	2.334	2.302	2.277	2.259	2.244
10	968.6	39.40	14.42	8.844	6.619	5.461	4.761	4.295	3.964	3.717	3.060	2.774	2.511	2.388	2.317	2.270	2.237	2.213	2.194	2.179
15	984.9	39.43	14.25	8.657	6.428	5.269	4.568	4.101	3.769	3.522	2.862	2.573	2.307	2.182	2.109	2.061	2.028	2.003	1.983	1.968
20	993.1	39.45	14.17	8.560	6.329	5.168	4.467	3.999	3.667	3.419	2.756	2.464	2.195	2.068	1.993	1.944	1.910	1.884	1.864	1.849
30	1001.	39.46	14.08	8.461	6.227	5.065	4.362	3.894	3.560	3.311	2.644	2.349	2.074	1.943	1.866	1.815	1.779	1.752	1.731	1.715
40	1006.	39.47	14.04	8.411	6.175	5.012	4.309	3.840	3.505	3.255	2.585	2.287	2.009	1.875	1.796	1.744	1.707	1.679	1.657	1.640
50	1008.	39.48	14.01	8.381	6.144	4.980	4.276	3.807	3.472	3.221	2.549	2.249	1.968	1.832	1.752	1.699	1.660	1.632	1.61	1.592
60	1010.	39.48	13.99	8.360	6.123	4.959	4.254	3.784	3.449	3.198	2.524	2.223	1.940	1.803	1.721	1.667	1.628	1.599	1.576	1.558
70	1011.	39.48	13.98	8.346	6.107	4.943	4.239	3.768	3.433	3.182	2.506	2.205	1.920	1.781	1.698	1.643	1.604	1.574	1.551	1.532
80	1012.	39.48	13.97	8.335	6.096	4.932	4.227	3.756	3.421	3.169	2.493	2.190	1.904	1.764	1.681	1.625	1.585	1.555	1.531	1.512
90	1013.	39.49	13.96	8.326	6.087	4.923	4.218	3.747	3.411	3.160	2.482	2.179	1.892	1.751	1.667	1.611	1.570	1.540	1.516	1.496
100	1013.	39.49	13.96	8.319	6.080	4.915	4.210	3.739	3.403	3.152	2.474	2.170	1.882	1.741	1.656	1.599	1.558	1.527	1.503	1.483

Quantile der  $F$ -Verteilung  $F_{m,n;\alpha}$  mit  $\alpha = 0.99$

$m$	$n$																			
	1	2	3	4	5	6	7	8	9	10	15	20	30	40	50	60	70	80	90	100
1	4052.	98.50	34.12	21.20	16.26	13.74	12.25	11.26	10.56	10.04	8.683	8.096	7.562	7.314	7.171	7.077	7.011	6.963	6.925	6.895
2	5000.	99.00	30.82	18.00	13.27	10.92	9.547	8.649	8.022	7.559	6.359	5.849	5.390	5.179	5.057	4.977	4.922	4.881	4.849	4.824
3	5403.	99.12	29.46	16.69	12.06	9.780	8.451	7.591	6.992	6.552	5.417	4.938	4.510	4.313	4.199	4.126	4.074	4.036	4.007	3.984
4	5625.	99.25	28.71	15.98	11.39	9.148	7.847	7.006	6.422	5.994	4.893	4.431	4.018	3.828	3.720	3.649	3.600	3.563	3.535	3.513
5	5764.	99.30	28.24	15.52	10.97	8.746	7.460	6.632	6.057	5.636	4.556	4.103	3.699	3.514	3.408	3.339	3.291	3.255	3.228	3.206
6	5859.	99.33	27.91	15.21	10.67	8.466	7.191	6.371	5.802	5.386	4.318	3.871	3.473	3.291	3.186	3.119	3.071	3.036	3.009	2.988
7	5928.	99.36	27.67	14.98	10.46	8.260	6.993	6.178	5.613	5.200	4.142	3.699	3.304	3.124	3.020	2.953	2.906	2.871	2.845	2.823
8	5981.	99.37	27.49	14.80	10.29	8.102	6.840	6.029	5.467	5.057	4.004	3.564	3.173	2.993	2.890	2.823	2.777	2.742	2.715	2.694
9	6022.	99.39	27.34	14.66	10.16	7.976	6.719	5.911	5.351	4.942	3.895	3.457	3.067	2.888	2.785	2.718	2.672	2.637	2.611	2.590
10	6056.	99.40	27.23	14.55	10.05	7.874	6.620	5.814	5.257	4.849	3.805	3.368	2.979	2.801	2.698	2.632	2.585	2.551	2.524	2.503
15	6157.	99.43	26.87	14.20	9.722	7.559	6.314	5.515	4.962	4.558	3.522	3.088	2.700	2.522	2.419	2.352	2.306	2.271	2.244	2.223
20	6209.	99.45	26.69	14.02	9.553	7.396	6.155	5.359	4.808	4.405	3.372	2.938	2.549	2.369	2.265	2.198	2.150	2.115	2.088	2.067
30	6261.	99.47	26.50	13.84	9.379	7.229	5.992	5.198	4.649	4.247	3.214	2.778	2.386	2.203	2.098	2.028	1.980	1.944	1.916	1.893
40	6287.	99.47	26.41	13.74	9.291	7.143	5.908	5.116	4.567	4.165	3.132	2.695	2.299	2.114	2.007	1.936	1.886	1.849	1.820	1.797
50	6302.	99.48	26.35	13.69	9.238	7.091	5.858	5.065	4.517	4.115	3.081	2.643	2.245	2.058	1.949	1.877	1.826	1.788	1.759	1.735
60	6313.	99.48	26.32	13.65	9.202	7.057	5.824	5.032	4.483	4.082	3.047	2.608	2.208	2.019	1.909	1.836	1.785	1.746	1.716	1.692
70	6321.	99.48	26.29	13.62	9.176	7.032	5.799	5.007	4.459	4.058	3.022	2.582	2.181	1.991	1.880	1.806	1.754	1.714	1.684	1.659
80	6326.	99.49	26.27	13.60	9.157	7.013	5.781	4.989	4.441	4.039	3.004	2.563	2.160	1.969	1.857	1.783	1.730	1.690	1.659	1.634
90	6331.	99.49	26.25	13.59	9.142	6.998	5.766	4.975	4.426	4.025	2.989	2.548	2.144	1.952	1.839	1.764	1.711	1.671	1.639	1.614
100	6334.	99.49	26.24	13.58	9.130	6.987	5.755	4.963	4.415	4.014	2.977	2.535	2.131	1.938	1.825	1.749	1.695	1.655	1.623	1.598

## 4.11 Kolmogoroff-Smirnoff-Test

Kritische Werte für den Kolmogoroff-Smirnoff-Test

$\alpha = W.$ (Fehler 1. Art)  $\rightsquigarrow$  kritischer Wert  $c_{n;1-\alpha}$

Testentscheidung: Teststatistik  $D > c_{n;1-\alpha} \rightsquigarrow H_0$  wird verworfen!

$n$	$\alpha$						
	0.2	0.1	0.08	0.05	0.04	0.02	0.01
1	0.900	0.950	0.960	0.975	0.980	0.990	0.995
2	0.684	0.776	0.800	0.842	0.859	0.900	0.929
3	0.565	0.636	0.658	0.708	0.729	0.785	0.829
4	0.493	0.565	0.585	0.624	0.641	0.689	0.734
5	0.447	0.509	0.527	0.563	0.580	0.627	0.669
6	0.410	0.468	0.485	0.519	0.534	0.577	0.617
7	0.381	0.436	0.452	0.483	0.497	0.538	0.576
8	0.358	0.410	0.425	0.454	0.468	0.507	0.542
9	0.339	0.387	0.402	0.430	0.443	0.480	0.513
10	0.323	0.369	0.382	0.409	0.421	0.457	0.489
11	0.308	0.352	0.365	0.391	0.403	0.437	0.468
12	0.296	0.338	0.351	0.375	0.387	0.419	0.449
13	0.285	0.325	0.338	0.361	0.372	0.404	0.432
14	0.275	0.314	0.326	0.349	0.359	0.390	0.418
15	0.266	0.304	0.315	0.338	0.348	0.377	0.404
16	0.258	0.295	0.306	0.327	0.337	0.366	0.392
17	0.250	0.286	0.297	0.318	0.327	0.355	0.381
18	0.244	0.279	0.289	0.309	0.319	0.346	0.371
19	0.237	0.271	0.281	0.301	0.310	0.337	0.361
20	0.232	0.265	0.275	0.294	0.303	0.329	0.352
21	0.226	0.259	0.268	0.287	0.296	0.321	0.344
22	0.221	0.253	0.262	0.281	0.289	0.314	0.337
23	0.216	0.247	0.257	0.275	0.283	0.307	0.330
24	0.212	0.242	0.251	0.269	0.277	0.301	0.323
25	0.208	0.238	0.246	0.264	0.272	0.295	0.317
26	0.204	0.233	0.242	0.259	0.267	0.290	0.311
27	0.200	0.229	0.237	0.254	0.262	0.284	0.305
28	0.197	0.225	0.233	0.250	0.257	0.279	0.300
29	0.193	0.221	0.229	0.246	0.253	0.275	0.295
30	0.190	0.218	0.226	0.242	0.249	0.270	0.290
31	0.187	0.214	0.222	0.238	0.245	0.266	0.285
32	0.184	0.211	0.219	0.234	0.241	0.262	0.281
33	0.182	0.208	0.215	0.231	0.238	0.258	0.277
34	0.179	0.205	0.212	0.227	0.234	0.254	0.273
35	0.177	0.202	0.209	0.224	0.231	0.251	0.269
36	0.174	0.199	0.206	0.221	0.228	0.247	0.265
37	0.172	0.196	0.204	0.218	0.225	0.244	0.262
38	0.170	0.194	0.201	0.215	0.222	0.241	0.258
39	0.168	0.191	0.199	0.213	0.219	0.238	0.255
40	0.165	0.189	0.196	0.210	0.216	0.235	0.252
Approximation für $n > 40$	$\frac{1.07}{\sqrt{n}}$	$\frac{1.22}{\sqrt{n}}$	$\frac{1.27}{\sqrt{n}}$	$\frac{1.36}{\sqrt{n}}$	$\frac{1.40}{\sqrt{n}}$	$\frac{1.52}{\sqrt{n}}$	$\frac{1.63}{\sqrt{n}}$

Die Approximation lässt sich verbessern, wenn man statt  $\sqrt{n}$  den Ausdruck  $(\sqrt{n} + 0.12 + 0.11/\sqrt{n})$  verwendet, z. B. für  $n = 40$  ergeben sich mit 0.166 0.189 0.196 0.210 0.217 0.235 0.252 nur geringfügige Abweichungen zu den genauen Werten.

	Excel	SPSS	STATA
<code>ks.test(x, ...)</code>	<addon only>	[Analysieren->NP Tests->K-S]	ksmirnov

# Index

- $\alpha$ -Niveau-Test, 29
- Abhängigkeitstest, 31
- Anpassungstest, 34
- Approximationen, 25
  
- Bayes, Satz von, 18
- Bedingte Verteilungen, 21
- Bestimmtheitsmaß, 15
- Binomialkoeffizient, 19
- Bivariates, 6, 21
- Boxplot, 8
  
- $\chi^2$ -Maß, 12
- $\chi^2$ -Test
  - Anpassungs-, 35
  - Unabhängigkeits-, 32
  
- Dichte, 20
  - bedingte, 21
  
- Einstichprobentests, 45
- Ereignis, 16
- Erwartungstreue, 27
- Erwartungswert, 22
  
- Fakultät, 19
- Fehler 1., 2. Art, 28
- Fisher-Test, 33
  
- Ginikoeffizient, 11
- Grenzwertsatz
  - Moivre-Laplace, 25
  - Poisson, 25
- Grundgesamtheit, 4, 16
- Gütefunktion, 29
  
- Histogramm, 5
- Homoskedastizität, 37
- Häufigkeit, 4
  
- Indexzahlen, 10
- Indizes
  - nach Laspeyres, 10
  - nach Paasche, 10
  - Umbasieren, 10
  - Verketten, 10
  
- Kolmogoroff-Smirnoff-Test, 34, 58
- Kombinationen, 18
  
- Konfidenzintervalle, 28, 44
- Konsistenz, 27
- Kontingenzkoeffizient
  - Pearsonscher, 13
- Kontingenztafel, 6
- Konzentrationsindizes, 12
- Konzentrationskurve, 12
- Korrelation
  - lineare, 24
- Korrelationskoeffizient
  - Bravais-Pearson-, 13
  - Spearman-, 14
- Korrelationstest, 31
- Kovarianz, 23
  - Empirische, 13
  
- Lineare Regression
  - Einfache
    - Empirische, 14
  - Multiple
    - Empirische, 15
- Lorenzkurve, 11
  
- MAD, 9
- Maximum-Likelihood-Methode, 27
- Merkmal, 4
- messbarer Raum, 17
- Mittel
  - Arithmetisches, 7
  - Geometrisches, 7
  - Getrimmtes, 7
  - Harmonisches, 7
- Modus, 8
- Momenten-Schätzmethode, 27
- Multinomialkoeffizient, 19
  
- $p$ -Wert, 29
- Punktschätzverfahren, 27
  
- QQ-Plot, 35
- Quantil, 7
- Quantile der
  - $\chi^2$ -Vert., 51
  - $F$ -Vert., 53
  - NV, 49
  - $t$ -Vert., 50
- Quartil, 8
- Quartilsabstand, 8

## Index

- Randverteilung, 21
- Rang, 13
- Regressionsmodell, lineares
  - Prognose, 39
  - Tests im, 37
- Schätzer
  - Eigenschaften von, 27
- Shapiro-Wilk-Test, 36
- $\sigma$ -Algebra, 16
- Skalen, 4
- Spannweite, 8
- Standardabweichung, 23
  - Empirische, 9
- Statistik, 26
- Stetigkeitskorrektur, 25
- Stichprobenfunktionen, 26
  - spezielle, 26
- $t$ -Test
  - verbundener, 30
- Tschebyschoff-Ungleichung, 24
- Unabhängigkeit, stochastische, 18
- Unabhängigkeit
  - von Zufallsvariablen, 22
- Varianz, 23
  - Empirische, 9
  - Stichproben-, 9
- Variationen, 18
- Variationskoeffizient, 9
- Verschiebungssatz, 23
- Verteilung
  - Bernoulli-, 41
  - Binomial-, 41
  - Cauchy-, 42
  - $\chi^2$ -, 43
  - Exponential-, 42
  - $F$ -, Fisher-, 43
  - Gamma-, 42
  - Geometrische, 41
  - Gleich-, 42
  - Hypergeometrische, 41
  - Laplace-, 42
  - Normal-, 43
  - Poission, 41
  - $t$ -, Student-, 43
- Verteilungsf. der NV, 47
- Verteilungsfunktion, 19
  - 2-dimensionale, 21
  - Empirische, 5
- Wahrscheinlichkeit
  - bedingte, 17
  - Laplace-, 17
  - totale, 18
- Wahrscheinlichkeitsdichte, 20
- Wahrscheinlichkeitsfunktion, 20
- Wahrscheinlichkeitsmaß, 17
- Wahrscheinlichkeitsraum, 17
- Zentraler Grenzwertsatz, 24
- Ziehungen  $k$  aus  $n$ , 18
- Zufallsstichproben, 26
- Zufallsvariable, 19
  - diskrete, 20
  - stetige, 20
- Zufallsvariablen
  - Summen von, 25
- Zweistichprobentests, 46