

Statistik Workshop

Mini-Einführung und Auffrischung zu einigen Teilen der
angewandten Statistik

12. und 14. Januar 2015

Prof. Dr. Stefan Etschberger
HSA



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse

1 Statistik: Einführung

- Fehler durch Statistik
- Gute und schlechte Grafiken
- Begriff Statistik
- Grundbegriffe der Datenerhebung
- R und RStudio

2 Deskriptive Statistik

- Häufigkeiten
- Lage und Streuung
- Konzentration
- Zwei Merkmale
- Korrelation
- Lineare Regression

3 Wahrscheinlichkeitstheorie

- Kombinatorik
- Zufall und Wahrscheinlichkeit
- Zufallsvariablen und Verteilungen
- Verteilungsparameter

4 Induktive Statistik

- Grundlagen
- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests

5 Datenanalyse Einleitung

- Grundbegriffe
- Anwendungsbereiche
- Dreiteilung der Datenanalyse
- Datenanalyse: Prozess

- 1 Statistik: Einführung
- 2 Deskriptive Statistik
- 3 Wahrscheinlichkeitstheorie
- 4 Induktive Statistik
- 5 Datenanalyse Einleitung



- 3 Wahrscheinlichkeitstheorie
 - Kombinatorik
 - Zufall und Wahrscheinlichkeit
 - Zufallsvariablen und Verteilungen
 - Verteilungsparameter





2-mal Würfeln, das heißt Auswahl von $k = 2$ aus $n = 6$ Zahlen.



| | | | | | |
|-------|-------|-------|-------|-------|-------|
| (1,1) | (1,2) | (1,3) | (1,4) | (1,5) | (1,6) |
| (2,1) | (2,2) | (2,3) | (2,4) | (2,5) | (2,6) |
| (3,1) | (3,2) | (3,3) | (3,4) | (3,5) | (3,6) |
| (4,1) | (4,2) | (4,3) | (4,4) | (4,5) | (4,6) |
| (5,1) | (5,2) | (5,3) | (5,4) | (5,5) | (5,6) |
| (6,1) | (6,2) | (6,3) | (6,4) | (6,5) | (6,6) |

- ▶ mit WH, mit RF: alle Möglichkeiten, $6^2 = 36$
- ▶ ohne WH, mit RF: Diagonale entfällt, $36 - 6 = 30 = 6 \cdot 5 = \frac{6!}{(6-2)!}$

- ▶ ohne WH, ohne RF: Hälfte des letzten Ergebnisses: $\frac{30}{2} = 15 = \frac{6!}{4!2!} = \binom{6}{2}$
- ▶ mit WH, ohne RF: Letztes Ergebnis plus Diagonale, $15 + 6 = 21 = \binom{7}{2}$

Auswahl von k aus n Dingen

| | mit Wiederholung | ohne Wiederholung |
|------------------|--------------------|---------------------|
| mit Reihenfolge | n^k | $\frac{n!}{(n-k)!}$ |
| ohne Reihenfolge | $\binom{n+k-1}{k}$ | $\binom{n}{k}$ |



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
 - Kombinatorik
 - Zufall und Wahrscheinlichkeit
 - Zufallsvariablen und Verteilungen
 - Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

- ▶ **Zufallsvorgang:** Geschehen mit ungewissem Ausgang, z.B. Münzwurf
- ▶ **Elementarereignis** ω : Ein möglicher Ausgang, z.B. „Kopf“
Elementarereignisse schließen sich gegenseitig aus („Kopf“ oder „Zahl“)!
- ▶ **Ergebnismenge** Ω : Menge aller ω
- ▶ **Beispiel:** Werfen zweier Würfel:

$$\Omega : \left\{ \begin{array}{cccc} (1,1) & (1,2) & \cdots & (1,6) \\ (2,1) & (2,2) & \cdots & (2,6) \\ \vdots & \vdots & \ddots & \vdots \\ (6,1) & (6,2) & \cdots & (6,6) \end{array} \right\}$$

$$\Rightarrow \Omega = \{(x_1, x_2) : x_1, x_2 \in \{1, \dots, 6\}\}$$



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

- ▶ **Ereignis** A : Folgeerscheinung eines Elementarereignisses
- ▶ Formal:

$$A \subset \Omega$$

- ▶ Ereignisse schließen sich nicht gegenseitig aus!
- ▶ **Beispiel**: Werfen zweier Würfel:

| Ereignis | verbal | formal |
|----------|----------------|----------------------------------|
| A | Augensumme = 4 | $\{(1,3), (2,2), (3,1)\}$ |
| B | Erste Zahl = 2 | $\{(2,1), (2,2), \dots, (2,6)\}$ |

- ▶ **Wahrscheinlichkeit** $P(A)$: Chance für das Eintreten von A
- ▶ **Laplace-Wahrscheinlichkeit**:

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



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

- ▶ **Beispiel:** Werfen zweier Würfel:

$$\text{Augensumme} = 4 : A = \{(1,3), (2,2), (3,1)\}$$

$$|\Omega| = 36, |A| = 3 \Rightarrow P(A) = \frac{3}{36} = \frac{1}{12} = 0,083$$

- ▶ **Urnenmodell:** Ziehe n Objekte aus einer Menge mit N Objekten
Anzahl Möglichkeiten:

mit Zurücklegen: N^n

ohne Zurücklegen: $N \cdot (N - 1) \cdot \dots \cdot (N - (n - 1)) = \frac{N!}{(N-n)!}$

- ▶ **Beispiel:**

Wie groß ist die Wahrscheinlichkeit, aus einem gut gemischten 32-er Kartenblatt bei viermaligem Ziehen vier Asse zu bekommen?

- Ziehen mit Zurücklegen,
- Ziehen ohne Zurücklegen



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen



Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

► Wichtige Rechenregeln:

1. $P(A) \leq 1$
2. $P(\emptyset) = 0$
3. $A \subset B \Rightarrow P(A) \leq P(B)$
4. $P(\bar{A}) = 1 - P(A)$
5. $P(A \cup B) = P(A) + P(B) - P(A \cap B)$



► Beispiel:


$$P(\text{„Augenzahl} \leq 5\text{“}) = 1 - P(\text{„Augenzahl} = 6\text{“}) = 1 - \frac{1}{6} = \frac{5}{6}$$

Der Fall Sally Clark

- ▶ Sally Clarks Söhne Christopher und Harry sterben 1996 und 1997 beide kurz nach der Geburt an plötzlichem Kindstod.
- ▶ Kinderarzt: „Wahrscheinlich Mord, da 2 maliger plötzlicher Kindstod sehr unwahrscheinlich!“ (ohne konkrete Hinweise)
- ▶ Gerichtliche Untersuchung
- ▶ Hauptargument der Anklage gestützt durch Gerichtsgutachter Sir Roy Meadow (renommierter Facharzt für Kinderheilkunde): Wahrscheinlichkeit für plötzlichen Kindstod ist 1:8500, d.h. Wahrscheinlichkeit für 2 maliges Auftreten in einer Familie

$$p = \left(\frac{1}{8500} \right)^2 \approx 1 : 72\,000\,000$$

- ▶ Urteil: Doppelmord; Strafe: 2 mal lebenslang; Inhaftierung von Sally Clark 1999



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
Kombinatorik
Zufall und Wahrscheinlichkeit
Zufallsvariablen und Verteilungen
Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse

Der Fall Sally Clark

- ▶ Problem: Es gibt sehr viele Familien mit 2 Kindern
- ▶ Europa: ca. 80 Mio Familien mit Kindern, davon ca. 50% mit mindestens zwei Kindern, also ca. 40 Mio.
- ▶ Wahrscheinlichkeit, dass in einer solchen Familie kein zweifacher plötzlicher Kindstod auftritt: $1 - \left(\frac{1}{8500}\right)^2$
Annahmen:
 - Jede dieser Familien hat genau 2 Kinder; in Wirklichkeit: ca. 20% dieser Familien haben mindestens 3 Kinder
 - Zweiter plötzlicher Kindstod unabhängig von erstem (nicht untersucht)
- ▶ Wahrscheinlichkeit, dass in 40 Mio. Familien mindestens ein zweifacher plötzlicher Kindstod auftritt:

$$1 - \left(1 - \left(\frac{1}{8500}\right)^2\right)^{40\,000\,000} \approx 42,5\%$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
Kombinatorik
Zufall und Wahrscheinlichkeit
Zufallsvariablen und Verteilungen
Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse

Der Fall Sally Clark

- ▶ Problem: Es gibt sehr viele Familien mit 2 Kindern
- ▶ Europa: ca. 80 Mio Familien mit Kindern, davon ca. 50% mit mindestens zwei Kindern, also ca. 40 Mio.
- ▶ Wahrscheinlichkeit, dass in einer solchen Familie kein zweifacher plötzlicher Kindstod auftritt: $1 - \left(\frac{1}{8500}\right)^2$
Annahmen:
 - Jede dieser Familien hat genau 2 Kinder; in Wirklichkeit: ca. 20% dieser Familien haben mindestens 3 Kinder
 - Zweiter plötzlicher Kindstod unabhängig von erstem (nicht untersucht)
- ▶ Wahrscheinlichkeit, dass in 40 Mio. Familien mindestens ein zweifacher plötzlicher Kindstod auftritt:

$$1 - \left(1 - \left(\frac{1}{8500}\right)^2\right)^{40\,000\,000} \approx 42,5\%$$

- ▶ 2001: Royal Statistical Society interveniert
- ▶ 2003: Sally Clark wird nach Revision freigesprochen
- ▶ 2007 findet man sie tot in ihrer Wohnung auf - gestorben an einer akuten Alkoholvergiftung. Sie habe sich, so ihre Familie, von dem Justizirrtum nie erholt.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
Kombinatorik
Zufall und Wahrscheinlichkeit
Zufallsvariablen und Verteilungen
Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter


4. Induktive Statistik

5. Datenanalyse

- ▶ Wahrscheinlichkeit von A hängt von anderem Ereignis B ab.
(B kann zeitlich vor A liegen, muss aber nicht!)
- ▶ **Beispiel:** Wahrscheinlichkeit für Statistiknote hängt von Mathenote ab.
- ▶ Formal:

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

- ▶ Im Venndiagramm:





1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

- ▶ A, B **unabhängig**: Eintreten von A liefert keine Information über P(B).

- ▶ Formal:

$$P(A | B) = P(A)$$

- ▶ Bei **Unabhängigkeit** ist äquivalent dazu:

$$P(A \cap B) = P(A) \cdot P(B)$$

- ▶ Dann gilt:

$$P(A \cup B) = P(A) + P(B) - P(A) \cdot P(B)$$

- ▶ **Beispiel**: Werfen zweier Würfel:

$$\left. \begin{array}{l} A : \text{"erster Würfel gleich 6"} \\ B : \text{"zweiter Würfel gleich 6"} \end{array} \right\} \Rightarrow P(A | B) = \frac{P(A \cap B)}{P(B)}$$
$$= \frac{1}{36} = \frac{1}{6}$$
$$= P(A)$$



Zufallsvariablen und Verteilungen

- ▶ Beschreibung von Ereignissen durch reelle Zahlen
- ▶ Formal: **Zufallsvariable** ist Abbildung von Ereignisraum in reelle Zahlen:

$$X: \Omega \rightarrow \mathbb{R}$$

- ▶ **Nach** Durchführung des Zufallsvorgangs:


Realisation: $x = X(\omega)$

- ▶ **Vor** Durchführung des Zufallsvorgangs:

Wertebereich: $X(\Omega) = \{x : x = X(\omega), \omega \in \Omega\}$

- ▶ **Beispiel:** Würfeln, X : Augenzahl, $X(\Omega) = \{1, 2, \dots, 6\}$, $x = 4$ (z.B.)

$$P(X = 4) = \frac{1}{6}, \quad P(X \leq 3) = \frac{3}{6} = \frac{1}{2}$$



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

► Zuweisung von Wahrscheinlichkeiten zu Realisationen


► Formal:

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

► Eigenschaften der **Verteilungsfunktion**:

- $F(x) \in [0; 1]$
- Definitionsbereich: \mathbb{R} mit $F(-\infty) = 0$, $F(\infty) = 1$
- monoton wachsend, d.h. $x_1 < x_2 \Rightarrow F(x_1) \leq F(x_2)$
- Es gilt:

$$P(a < X \leq b) = F(b) - F(a)$$



Beispiel einer Verteilungsfunktion



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse





- ▶ X heißt **diskret**, wenn $X(\Omega) = \{x_1, x_2, \dots\}$ endlich ist.
- ▶ Wahrscheinlichkeitsfunktion dann:

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

Beispiel: Münze 2 mal werfen; X : Anzahl "Kopf"

| | (Z, Z) | (Z, K), (K, Z) | (K, K) |
|----------|---------------|----------------|---------------|
| x_i | 0 | 1 | 2 |
| $f(x_i)$ | $\frac{1}{4}$ | $\frac{1}{2}$ | $\frac{1}{4}$ |

$$F(x) = \begin{cases} 0, & \text{falls } x < 0 \\ \frac{1}{4}, & \text{falls } 0 \leq x < 1 \\ \frac{3}{4}, & \text{falls } 1 \leq x < 2 \\ 1, & \text{falls } x \geq 2 \end{cases}$$



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit


Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

$$P(A) = p$$



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

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

$$\dots = "$$

$x \hat{=}$ Anzahl Treffer bei 3 Versuchen

$$P(X=3) = 3 \cdot p \cdot (1-p)^2$$

- ▶ **Wiederholter** Zufallsvorgang
- ▶ n Durchführungen (jeweils unabhängig)
- ▶ Pro Durchföhrung: A oder \bar{A} mit $P(A) = p$ ($\hat{=}$ Ziehen mit Zurücklegen)
- ▶ Schreibe:

$$X_i = \begin{cases} 1, & \text{falls } A \text{ bei } i\text{-ter Durchföhrung eintritt} \\ 0, & \text{falls } \bar{A} \text{ bei } i\text{-ter Durchföhrung eintritt} \end{cases}$$

- ▶ Dann gibt

$$X = \sum_{i=1}^n X_i$$

an, wie oft A eintritt.

- ▶ Gesucht: Wahrscheinlichkeitsfunktion von X



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
 - Kombinatorik
 - Zufall und Wahrscheinlichkeit
 - Zufallsvariablen und Verteilungen
 - Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

► Herleitung:

1) $P(X_i = 1) = P(A) = p$, $P(X_i = 0) = P(\bar{A}) = 1 - p$

2) $\sum_{i=1}^n x_i = x$ entspricht "x mal Ereignis A und n - x mal \bar{A} "

Wahrscheinlichkeit (bei Unabhängigkeit): $p^x \cdot (1 - p)^{n-x}$

3) Aber: Reihenfolge irrelevant! Anzahl Anordnungen: $\binom{n}{x}$

► Wahrscheinlichkeitsfunktion der Binomialverteilung:

$$f(x) = \begin{cases} \binom{n}{x} \cdot p^x \cdot (1 - p)^{n-x}, & \text{falls } x \in \{0, 1, \dots, n\} \\ 0, & \text{sonst} \end{cases}$$

► Kurzschreibweise: $X \sim B(n; p)$

X ist binomialverteilt mit Parametern n und p

► Tabellen zeigen meist $F(x)$

► für $f(x)$ gilt: $f(x) = F(x) - F(x - 1)$

$X \sim B(n, 0.25)$, Tabelle der Binomialverteilung $F(x) = P(X \leq x)$



| $x \setminus n$ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 |
|-----------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0 | 0.7500 | 0.5625 | 0.4219 | 0.3164 | 0.2373 | 0.1780 | 0.1335 | 0.1001 | 0.0751 | 0.0563 | 0.0422 | 0.0317 | 0.0238 | 0.0178 | 0.0134 |
| 1 | 1.0000 | 0.9375 | 0.8438 | 0.7383 | 0.6328 | 0.5339 | 0.4450 | 0.3671 | 0.3003 | 0.2440 | 0.1971 | 0.1584 | 0.1267 | 0.1010 | 0.0802 |
| 2 | | 1.0000 | 0.9844 | 0.9492 | 0.8965 | 0.8306 | 0.7564 | 0.6786 | 0.6007 | 0.5256 | 0.4552 | 0.3907 | 0.3326 | 0.2811 | 0.2361 |
| 3 | | | 1.0000 | 0.9961 | 0.9844 | 0.9624 | 0.9295 | 0.8862 | 0.8343 | 0.7759 | 0.7133 | 0.6488 | 0.5843 | 0.5213 | 0.4613 |
| 4 | | | | 1.0000 | 0.9990 | 0.9954 | 0.9871 | 0.9727 | 0.9511 | 0.9219 | 0.8854 | 0.8424 | 0.7940 | 0.7415 | 0.6865 |
| 5 | | | | | 1.0000 | 0.9998 | 0.9987 | 0.9958 | 0.9900 | 0.9803 | 0.9657 | 0.9456 | 0.9198 | 0.8883 | 0.8516 |
| 6 | | | | | | 1.0000 | 0.9999 | 0.9996 | 0.9987 | 0.9965 | 0.9924 | 0.9858 | 0.9757 | 0.9617 | 0.9434 |
| 7 | | | | | | | 1.0000 | 0.9999 | 0.9996 | 0.9988 | 0.9972 | 0.9944 | 0.9897 | 0.9827 | |
| 8 | | | | | | | | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9996 | 0.9990 | 0.9979 | 0.9958 |
| 9 | | | | | | | | | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9997 | 0.9992 |
| 10 | | | | | | | | | | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 |
| 11 | | | | | | | | | | | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 |

| $x \setminus n$ | 16 | 17 | 18 | 19 | 20 | 21 | 22 | 23 | 24 | 25 | 26 | 27 | 28 | 29 | 30 |
|-----------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0 | 0.0100 | 0.0075 | 0.0056 | 0.0042 | 0.0032 | 0.0024 | 0.0018 | 0.0013 | 0.0010 | 0.0008 | 0.0006 | 0.0004 | 0.0003 | 0.0002 | 0.0002 |
| 1 | 0.0635 | 0.0501 | 0.0395 | 0.0310 | 0.0243 | 0.0190 | 0.0149 | 0.0116 | 0.0090 | 0.0070 | 0.0055 | 0.0042 | 0.0033 | 0.0025 | 0.0020 |
| 2 | 0.1971 | 0.1637 | 0.1353 | 0.1114 | 0.0913 | 0.0745 | 0.0607 | 0.0492 | 0.0398 | 0.0321 | 0.0258 | 0.0208 | 0.0166 | 0.0133 | 0.0106 |
| 3 | 0.4050 | 0.3530 | 0.3057 | 0.2631 | 0.2252 | 0.1917 | 0.1624 | 0.1370 | 0.1150 | 0.0962 | 0.0802 | 0.0666 | 0.0551 | 0.0455 | 0.0375 |
| 4 | 0.6302 | 0.5739 | 0.5187 | 0.4654 | 0.4149 | 0.3674 | 0.3235 | 0.2832 | 0.2467 | 0.2138 | 0.1844 | 0.1583 | 0.1354 | 0.1153 | 0.0979 |
| 5 | 0.8104 | 0.7653 | 0.7175 | 0.6678 | 0.6172 | 0.5666 | 0.5168 | 0.4685 | 0.4222 | 0.3783 | 0.3372 | 0.2990 | 0.2638 | 0.2317 | 0.2026 |
| 6 | 0.9205 | 0.8929 | 0.8610 | 0.8251 | 0.7858 | 0.7436 | 0.6994 | 0.6537 | 0.6074 | 0.5611 | 0.5154 | 0.4708 | 0.4279 | 0.3869 | 0.3481 |
| 7 | 0.9729 | 0.9598 | 0.9431 | 0.9226 | 0.8982 | 0.8701 | 0.8385 | 0.8037 | 0.7662 | 0.7265 | 0.6852 | 0.6427 | 0.5998 | 0.5568 | 0.5143 |
| 8 | 0.9925 | 0.9876 | 0.9807 | 0.9713 | 0.9591 | 0.9439 | 0.9254 | 0.9037 | 0.8787 | 0.8506 | 0.8196 | 0.7860 | 0.7502 | 0.7126 | 0.6736 |
| 9 | 0.9984 | 0.9969 | 0.9946 | 0.9911 | 0.9861 | 0.9794 | 0.9705 | 0.9592 | 0.9453 | 0.9287 | 0.9092 | 0.8868 | 0.8616 | 0.8337 | 0.8034 |
| 10 | 0.9997 | 0.9994 | 0.9988 | 0.9977 | 0.9961 | 0.9936 | 0.9900 | 0.9852 | 0.9787 | 0.9703 | 0.9599 | 0.9472 | 0.9321 | 0.9145 | 0.8943 |
| 11 | 1.0000 | 0.9999 | 0.9998 | 0.9995 | 0.9991 | 0.9983 | 0.9971 | 0.9954 | 0.9928 | 0.9893 | 0.9845 | 0.9784 | 0.9706 | 0.9610 | 0.9494 |
| 12 | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9998 | 0.9996 | 0.9993 | 0.9988 | 0.9979 | 0.9966 | 0.9948 | 0.9922 | 0.9888 | 0.9842 | 0.9784 |
| 13 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9999 | 0.9997 | 0.9995 | 0.9991 | 0.9985 | 0.9976 | 0.9962 | 0.9944 | 0.9918 |
| 14 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9998 | 0.9996 | 0.9993 | 0.9989 | 0.9982 | 0.9973 |
| 15 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9998 | 0.9997 | 0.9995 | 0.9992 |
| 16 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9999 | 0.9998 |
| 17 | | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 |
| 18 | | | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 |

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

Beispiel

Aus einem 32-er Kartenblatt wird **3-mal eine Karte mit Zurücklegen** gezogen.

Wie wahrscheinlich ist es, **2-mal Herz** zu ziehen?

$$X_i = \begin{cases} 1, & \text{falls } i\text{-te Karte Herz} \\ 0, & \text{sonst} \end{cases} \quad \Rightarrow \quad X_i \sim B\left(1; \frac{8}{32}\right)$$

$$X = \sum_{i=1}^n X_i = X_1 + X_2 + X_3 \quad \Rightarrow \quad X \sim B\left(3; \frac{1}{4}\right)$$

Mithilfe der **Wahrscheinlichkeitsfunktion**:

$$P(X = 2) = f(2) = \binom{3}{2} \cdot 0,25^2 \cdot 0,75^1 = 0,1406$$

Mithilfe der **Tabelle** ($n = 3$):

$$P(X = 2) = F(2) - F(1) = 0,9844 - 0,8438 = 0,1406$$



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

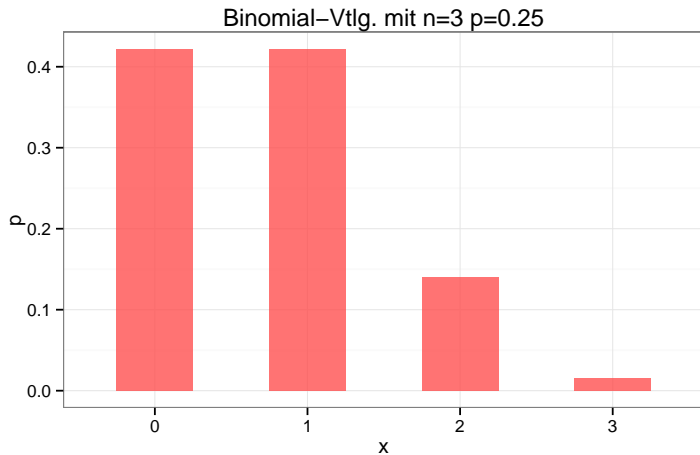
Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse



► $X \sim B(3, \frac{1}{4})$



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit


Zufallsvariablen und
Verteilungen

Verteilungsparameter


4. Induktive Statistik

5. Datenanalyse


Binomial-Vtlg. mit $n=10$ $p=0.25$




Binomial-Vtlg. mit $n=100$ $p=0.25$



Binomial-Vtlg. mit $n=30$ $p=0.25$



Binomial-Vtlg. mit $n=500$ $p=0.25$





1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

- ▶ n -faches Ziehen **ohne** Zurücklegen aus N Objekten, davon M markiert.

X = Anzahl gezogener Objekte mit Markierung

heißt **hypergeometrisch verteilt** mit den Parametern N , M , n .

- ▶ Kurzschreibweise: $X \sim \text{Hyp}(N; M; n)$
- ▶ Wahrscheinlichkeitsfunktion:

$$f(x) = \begin{cases} \frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}}, & \text{falls } x \text{ möglich} \\ 0, & \text{sonst} \end{cases}$$

- ▶ Ist $n \leq \frac{N}{20}$, so gilt: $\text{Hyp}(N; M; n) \approx B(n; \frac{M}{N})$



- ▶ Aus einem 32-Kartenblatt wird 3-mal eine Karte ohne Zurücklegen gezogen.
- ▶ Wie wahrscheinlich ist es, 2-mal "Herz" zu ziehen?
- ▶ D.h.: $N = 32$, $M = 8$, $n = 3$, $x = 2$.

$$\begin{aligned}P(X = 2) = f(2) &= \frac{\binom{8}{2} \binom{32-8}{3-2}}{\binom{32}{3}} = \frac{\binom{8}{2} \binom{24}{1}}{\binom{32}{3}} = \frac{8!}{2! \cdot 6!} \cdot 24 \\ &= \frac{29! \cdot 8! \cdot 3! \cdot 24}{32! \cdot 6! \cdot 2!} = \frac{8 \cdot 7 \cdot 3 \cdot 24}{32 \cdot 31 \cdot 30} = \frac{4032}{29760} = \frac{21}{155} \\ &= 0,1355\end{aligned}$$

Dabei wurde verwendet:

$$\binom{n}{k} = \frac{n!}{k!(n-k)!} \quad \text{und} \quad \binom{n}{1} = n.$$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter


4. Induktive Statistik

5. Datenanalyse

Beispiel: x Treffer im Lotto 6 aus 49

► $X \sim \text{Hyp}(49, 6, 6)$

| x | $P(X = x)$ (in %) |
|-----|-------------------|
| 0 | 43.596498 |
| 1 | 41.301945 |
| 2 | 13.237803 |
| 3 | 1.765040 |
| 4 | 0.096862 |
| 5 | 0.001845 |
| 6 | 0.000007 |



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
 - Kombinatorik
 - Zufall und Wahrscheinlichkeit
 - Zufallsvariablen und Verteilungen
 - Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

- ▶ Approximation für $B(n; p)$ und $Hyp(N; M; n)$
- ▶ Geeignet, wenn
 p klein ($\leq 0,1$), n groß (≥ 50) und $np \leq 10$.
- ▶ „Verteilung der seltenen Ereignisse“
(z.B. Anzahl 6-er pro Lottoauspielung)
- ▶ X ist **poissonverteilt mit Parameter λ** : $X \sim P(\lambda)$
- ▶ Wahrscheinlichkeitsfunktion:

$$f(x) = \begin{cases} \frac{\lambda^x}{x!} \cdot e^{-\lambda}, & \text{falls } x = 0, 1, 2, \dots \\ 0, & \text{sonst} \end{cases}$$

- ▶ $F(x)$ in Tabelle
- ▶ Überblick: Approximation

$$Hyp(N; M; n) \xrightarrow{p = \frac{M}{N}} B(n; p) \xrightarrow{\lambda = np = n \frac{M}{N}} P(\lambda)$$

Poissonverteilung: $X \sim P(\lambda)$, Tabelle der Verteilungsfunktionen



| $x \setminus \lambda$ | 1.6 | 1.7 | 1.8 | 1.9 | 2 | 2.1 | 2.2 | 2.3 | 2.4 | 2.5 | 2.6 | 2.7 | 2.8 | 2.9 | 3 |
|-----------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0 | 0.2019 | 0.1827 | 0.1653 | 0.1496 | 0.1353 | 0.1225 | 0.1108 | 0.1003 | 0.0907 | 0.0821 | 0.0743 | 0.0672 | 0.0608 | 0.0550 | 0.0498 |
| 1 | 0.5249 | 0.4933 | 0.4628 | 0.4338 | 0.4060 | 0.3796 | 0.3546 | 0.3309 | 0.3085 | 0.2873 | 0.2674 | 0.2487 | 0.2311 | 0.2146 | 0.1992 |
| 2 | 0.7834 | 0.7572 | 0.7306 | 0.7037 | 0.6767 | 0.6496 | 0.6227 | 0.5960 | 0.5697 | 0.5438 | 0.5184 | 0.4936 | 0.4695 | 0.4460 | 0.4232 |
| 3 | 0.9212 | 0.9068 | 0.8913 | 0.8747 | 0.8571 | 0.8387 | 0.8194 | 0.7994 | 0.7787 | 0.7576 | 0.7360 | 0.7141 | 0.6919 | 0.6696 | 0.6472 |
| 4 | 0.9763 | 0.9704 | 0.9636 | 0.9559 | 0.9474 | 0.9379 | 0.9275 | 0.9163 | 0.9041 | 0.8912 | 0.8774 | 0.8629 | 0.8477 | 0.8318 | 0.8153 |
| 5 | 0.9940 | 0.9920 | 0.9896 | 0.9868 | 0.9834 | 0.9796 | 0.9751 | 0.9700 | 0.9643 | 0.9580 | 0.9510 | 0.9433 | 0.9349 | 0.9258 | 0.9161 |
| 6 | 0.9987 | 0.9981 | 0.9974 | 0.9966 | 0.9955 | 0.9941 | 0.9925 | 0.9906 | 0.9884 | 0.9858 | 0.9828 | 0.9794 | 0.9756 | 0.9713 | 0.9665 |
| 7 | 0.9997 | 0.9996 | 0.9994 | 0.9992 | 0.9989 | 0.9985 | 0.9980 | 0.9974 | 0.9967 | 0.9958 | 0.9947 | 0.9934 | 0.9919 | 0.9901 | 0.9881 |
| 8 | 1.0000 | 0.9999 | 0.9999 | 0.9998 | 0.9998 | 0.9997 | 0.9995 | 0.9994 | 0.9991 | 0.9989 | 0.9985 | 0.9981 | 0.9976 | 0.9970 | 0.9962 |
| 9 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9998 | 0.9997 | 0.9996 | 0.9995 | 0.9993 | 0.9989 |
| 10 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9999 | 0.9999 | 0.9998 | 0.9998 | 0.9997 |
| 11 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 |
| 12 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 |

| $x \setminus \lambda$ | 3.1 | 3.2 | 3.3 | 3.4 | 3.5 | 3.6 | 3.7 | 3.8 | 3.9 | 4 | 4.1 | 4.2 | 4.3 | 4.4 | 4.5 |
|-----------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0 | 0.0451 | 0.0408 | 0.0369 | 0.0334 | 0.0302 | 0.0273 | 0.0247 | 0.0224 | 0.0203 | 0.0183 | 0.0166 | 0.0150 | 0.0136 | 0.0123 | 0.0111 |
| 1 | 0.1847 | 0.1712 | 0.1586 | 0.1469 | 0.1359 | 0.1257 | 0.1162 | 0.1074 | 0.0992 | 0.0916 | 0.0845 | 0.0780 | 0.0719 | 0.0663 | 0.0611 |
| 2 | 0.4012 | 0.3799 | 0.3594 | 0.3397 | 0.3209 | 0.3028 | 0.2854 | 0.2689 | 0.2531 | 0.2381 | 0.2238 | 0.2102 | 0.1974 | 0.1852 | 0.1736 |
| 3 | 0.6248 | 0.6025 | 0.5803 | 0.5584 | 0.5366 | 0.5152 | 0.4942 | 0.4735 | 0.4533 | 0.4335 | 0.4142 | 0.3954 | 0.3772 | 0.3595 | 0.3423 |
| 4 | 0.7982 | 0.7806 | 0.7626 | 0.7442 | 0.7255 | 0.7064 | 0.6872 | 0.6679 | 0.6484 | 0.6288 | 0.6093 | 0.5898 | 0.5704 | 0.5512 | 0.5321 |
| 5 | 0.9057 | 0.8946 | 0.8829 | 0.8706 | 0.8576 | 0.8441 | 0.8301 | 0.8156 | 0.8006 | 0.7851 | 0.7693 | 0.7532 | 0.7367 | 0.7199 | 0.7029 |
| 6 | 0.9612 | 0.9554 | 0.9490 | 0.9422 | 0.9347 | 0.9267 | 0.9182 | 0.9091 | 0.8995 | 0.8893 | 0.8787 | 0.8675 | 0.8558 | 0.8437 | 0.8311 |
| 7 | 0.9858 | 0.9832 | 0.9802 | 0.9769 | 0.9733 | 0.9692 | 0.9648 | 0.9599 | 0.9546 | 0.9489 | 0.9427 | 0.9361 | 0.9290 | 0.9214 | 0.9134 |
| 8 | 0.9953 | 0.9943 | 0.9931 | 0.9917 | 0.9901 | 0.9883 | 0.9863 | 0.9840 | 0.9815 | 0.9786 | 0.9755 | 0.9721 | 0.9683 | 0.9642 | 0.9598 |
| 9 | 0.9986 | 0.9982 | 0.9978 | 0.9973 | 0.9967 | 0.9960 | 0.9952 | 0.9942 | 0.9931 | 0.9919 | 0.9905 | 0.9889 | 0.9871 | 0.9851 | 0.9829 |
| 10 | 0.9996 | 0.9995 | 0.9994 | 0.9992 | 0.9990 | 0.9987 | 0.9984 | 0.9981 | 0.9977 | 0.9972 | 0.9966 | 0.9959 | 0.9952 | 0.9943 | 0.9933 |
| 11 | 0.9999 | 0.9999 | 0.9998 | 0.9998 | 0.9997 | 0.9996 | 0.9995 | 0.9994 | 0.9993 | 0.9991 | 0.9989 | 0.9986 | 0.9983 | 0.9980 | 0.9976 |
| 12 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9999 | 0.9999 | 0.9998 | 0.9998 | 0.9997 | 0.9997 | 0.9996 | 0.9995 | 0.9994 | 0.9992 |
| 13 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9998 | 0.9998 |
| 14 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 0.9999 |
| 15 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 | 1.0000 |

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse



Beispiel

- ▶ $X \sim B(10\,000; 0,0003)$; In Tabelle der Binomialverteilung nicht vertafelt! Approximation:

$$\left. \begin{array}{l} p = 0,0003 < 0,1 \\ n = 10\,000 > 50 \\ np = 3 < 10 \end{array} \right\} \Rightarrow B(10\,000; 0,0003) \approx P(3)$$

- ▶ Mithilfe der Wahrscheinlichkeitsfunktion:

$$P(X = 5) = \frac{3^5}{5!} \cdot e^{-3} = 0,1008188$$

- ▶ Mithilfe der Tabelle der Poissonverteilung:

$$P(X = 5) = F(5) - F(4) = 0,9161 - 0,8153 = 0,1008$$

- ▶ Exakter Wert: $P(X = 5) = 0,1008239$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit





Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

Poisson- versus Binomialverteilung: Vergleich



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik



5. Datenanalyse

- ▶ X heißt **stetig**,
wenn $F(x)$ stetig ist.

- ▶ Dann existiert ein $f(t)$ mit:


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

$f(x)$ heißt **Dichtefunktion**
von X .



- ▶ Dann:

$$\begin{aligned} P(a < X < b) &= P(a \leq X < b) \\ &= P(a < X \leq b) \\ &= P(a \leq X \leq b) \\ &= \int_a^b f(x) dx \\ &= F(b) - F(a) \end{aligned}$$



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse



Eigenschaften der Dichtefunktion

- ▶ $f(x) \geq 0$ für alle $x \in \mathbb{R}$
- ▶ Wegen $F(\infty) = 1$ muss stets gelten:

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

- ▶ $P(X = x) = 0$ für alle $x \in \mathbb{R}$
- ▶ $f(x) > 1$ ist möglich
- ▶ für $x \in \mathbb{R}$ ist $F(x)$ differenzierbar $\Rightarrow F'(x) = f(x)$.
- ▶ Intervallgrenzen spielen keine Rolle:

$$\begin{aligned} P(X \in [a; b]) &= P(X \in (a; b]) \\ &= P(X \in [a; b)) \\ &= P(X \in (a; b)) \\ &= F(b) - F(a) \end{aligned}$$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit


Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

Beispiel



$$f(x) = \begin{cases} 0, & \text{falls } x < 0 \\ \frac{1}{10}, & \text{falls } 0 \leq x \leq 10 \\ 0, & \text{falls } x > 10 \end{cases}$$

Verteilungsfunktion:

$$\int_0^x f(t) dt = \int_0^x \frac{1}{10} dt = \left[\frac{t}{10} \right]_0^x = \frac{x}{10} \Rightarrow$$

$$F(x) = \begin{cases} 0, & \text{falls } x < 0 \\ \frac{x}{10}, & \text{falls } 0 \leq x \leq 10 \\ 1, & \text{falls } x > 10 \end{cases}$$



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter


4. Induktive Statistik

5. Datenanalyse

Eine Zufallsvariable X mit

$$f(x) = \begin{cases} \frac{1}{b-a}, & \text{falls } a \leq x \leq b \\ 0, & \text{sonst} \end{cases}$$


heißt **gleichverteilt** im Intervall $[a; b]$.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
Kombinatorik
Zufall und Wahrscheinlichkeit
Zufallsvariablen und Verteilungen
Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse



► Verteilungsfunktion der Gleichverteilung:



$$F(x) = \begin{cases} 0, & \text{falls } x < a \\ \frac{x-a}{b-a}, & \text{falls } a \leq x \leq b \\ 1, & \text{falls } x > b \end{cases}$$

► Beispiel: X gleichverteilt in [1; 20]

$$\begin{aligned} P(2 \leq X \leq 12) &= F(12) - F(2) = \frac{12-1}{20-1} - \frac{2-1}{20-1} \\ &= \frac{12-2}{20-1} = \frac{10}{19} \\ &= 0,5263 \end{aligned}$$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse




Eine Zufallsvariable X mit einer Dichtefunktion

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

und $\sigma > 0$ heißt **normalverteilt**.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
 - Kombinatorik
 - Zufall und Wahrscheinlichkeit
 - Zufallsvariablen und Verteilungen
 - Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse



2- σ -Bereich: $P(|x-\mu| < 2\sigma) \approx 95\%$
 3- σ -Bereich: $P(|x-\mu| < 3\sigma) \approx 99,8\%$

Kurzschreibweise: $X \sim N(\mu; \sigma)$

1-Sigma-Bereich: $P(|x-\mu| < \sigma) \approx 68\%$



Normalverteilung

C.F. Gauß




1. Einführung
2. Deskriptive Statistik
3. W-Theorie
 - Kombinatorik
 - Zufall und Wahrscheinlichkeit
 - Zufallsvariablen und Verteilungen
 - Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse

Verteilungsfunktion Φ der Standardnormalverteilung

Dabei bedeutet $\Phi(x)$ zum Beispiel: $\Phi(2,13) = \Phi(2,1 + 0,03) = 0,9834$. Diesen Wert findet man in der Zeile mit $x_1 = 2,1$ und der Spalte mit $x_2 = 0,03$.

| $x_1 \setminus x_2$ | 0 | 0.01 | 0.02 | 0.03 | 0.04 | 0.05 | 0.06 | 0.07 | 0.08 | 0.09 |
|---------------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 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 | 0.5754 |
| 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 | 0.6737 | 0.6773 | 0.6808 | 0.6844 | 0.6879 |
| 0.5 | 0.6915 | 0.6950 | 0.6985 | 0.7020 | 0.7054 | 0.7089 | 0.7123 | 0.7157 | 0.7191 | 0.7224 |
| 0.6 | 0.7258 | 0.7291 | 0.7324 | 0.7357 | 0.7389 | 0.7422 | 0.7454 | 0.7486 | 0.7518 | 0.7549 |
| 0.7 | 0.7580 | 0.7612 | 0.7642 | 0.7673 | 0.7704 | 0.7734 | 0.7764 | 0.7794 | 0.7823 | 0.7852 |
| 0.8 | 0.7882 | 0.7910 | 0.7939 | 0.7967 | 0.7996 | 0.8023 | 0.8051 | 0.8079 | 0.8106 | 0.8133 |
| 0.9 | 0.8159 | 0.8186 | 0.8212 | 0.8238 | 0.8264 | 0.8290 | 0.8315 | 0.8340 | 0.8365 | 0.8389 |
| 1 | 0.8414 | 0.8438 | 0.8461 | 0.8485 | 0.8508 | 0.8532 | 0.8554 | 0.8577 | 0.8599 | 0.8622 |
| 1.1 | 0.8643 | 0.8665 | 0.8687 | 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 | 0.9083 | 0.9099 | 0.9115 | 0.9131 | 0.9147 | 0.9162 | 0.9177 |
| 1.4 | 0.9193 | 0.9207 | 0.9222 | 0.9237 | 0.9251 | 0.9265 | 0.9279 | 0.9292 | 0.9306 | 0.9319 |
| 1.5 | 0.9332 | 0.9345 | 0.9358 | 0.9370 | 0.9382 | 0.9394 | 0.9406 | 0.9418 | 0.9430 | 0.9441 |
| 1.6 | 0.9452 | 0.9463 | 0.9474 | 0.9485 | 0.9495 | 0.9505 | 0.9516 | 0.9526 | 0.9535 | 0.9545 |
| 1.7 | 0.9554 | 0.9564 | 0.9573 | 0.9582 | 0.9591 | 0.9600 | 0.9608 | 0.9616 | 0.9625 | 0.9633 |
| 1.8 | 0.9641 | 0.9649 | 0.9656 | 0.9664 | 0.9671 | 0.9679 | 0.9686 | 0.9693 | 0.9700 | 0.9706 |
| 1.9 | 0.9713 | 0.9719 | 0.9726 | 0.9732 | 0.9738 | 0.9744 | 0.9750 | 0.9756 | 0.9762 | 0.9767 |
| 2 | 0.9773 | 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 | 0.9865 | 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 | 0.9914 | 0.9916 |
| 2.4 | 0.9918 | 0.9920 | 0.9922 | 0.9925 | 0.9927 | 0.9929 | 0.9931 | 0.9933 | 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 | 0.9975 | 0.9975 | 0.9976 | 0.9977 | 0.9978 | 0.9978 | 0.9979 | 0.9980 | 0.9980 | 0.9981 |
| 2.9 | 0.9981 | 0.9982 | 0.9983 | 0.9983 | 0.9984 | 0.9984 | 0.9985 | 0.9985 | 0.9986 | 0.9986 |
| 3 | 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 | 0.9995 | 0.9995 | 0.9995 | 0.9995 |



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
 - Kombinatorik
 - Zufall und Wahrscheinlichkeit
 - Zufallsvariablen und Verteilungen
 - Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse



- ▶ Dichte ist symmetrisch zu μ :

$$f(\mu - x) = f(\mu + x)$$

- ▶ μ ist Lage-, σ ist Streuungsparameter

- ▶ **Standardnormalverteilung:**

$N(0; 1)$ mit Verteilungsfunktion $\Phi(x)$ (\rightarrow Tabelle 3)

- ▶ Kenntnis von $\Phi(x)$, μ und σ genügt, denn:

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

$$F(x) = \Phi\left(\frac{x - \mu}{\sigma}\right)$$

- ▶ Tabelle enthält nur positive x : Deswegen

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

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse



Beispiel:

Projektdauer $X \sim N(39; 2)$.

Wahrscheinlichkeit für Projektdauer zwischen 37 und 41 Wochen?

Lösung:

$$\begin{aligned} P(37 \leq X \leq 41) &= F(41) - F(37) \\ &= \Phi\left(\frac{41-39}{2}\right) - \Phi\left(\frac{37-39}{2}\right) \\ &= \Phi(1) - \Phi(-1) \\ &= \Phi(1) - [1 - \Phi(1)] \\ &= 2 \cdot \Phi(1) - 1 \\ &= 2 \cdot 0,8413 - 1 \\ &= 0,6826 \end{aligned}$$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

- a) **Modus** x_{Mod} : $f(x_{\text{Mod}}) \geq f(x)$ für alle x
(i.A. nicht eindeutig, z.B. Gleichverteilung)

Beispiele:

- Normalverteilung: $x_{\text{Mod}} = \mu$
- Diskrete Verteilung mit:

| | | | |
|--------|---------------|---------------|---------------|
| x | 0 | 1 | 2 |
| $f(x)$ | $\frac{1}{4}$ | $\frac{1}{2}$ | $\frac{1}{4}$ |


$$\left. \vphantom{\begin{matrix} x & 0 & 1 & 2 \\ f(x) & \frac{1}{4} & \frac{1}{2} & \frac{1}{4} \end{matrix}} \right\} \Rightarrow x_{\text{Mod}} = 1$$

- b) **Median** x_{Med} : $F(x_{\text{Med}}) = \frac{1}{2}$ bzw. kleinstes x mit $F(x) > \frac{1}{2}$

Beispiele:

- Normalverteilung: $x_{\text{Med}} = \mu$
- Diskrete Verteilung

$$\text{oben: } F(0) = \frac{1}{4} < \frac{1}{2}, F(1) = \frac{3}{4} > \frac{1}{2} \Rightarrow x_{\text{Med}} = 1$$





c) **α -Fraktile** x_α : $F(x_\alpha) = \alpha$ (für stetige Verteilungen)

Beispiel: $X \sim N(0; 1)$, $Y \sim N(3; 2)$

$$\begin{aligned}x_{0,975} &= 1,96 && \text{(Tab. 3)} \\x_{0,025} &= -x_{0,975} = -1,96 \\y_{0,025} &= 2 \cdot x_{0,025} + 3 = -0,92\end{aligned}$$

Hinweise:

- $x_{\text{Med}} = x_{0,5}$
- Wenn x_α nicht vertafelt \rightarrow **Interpolation:**

$$x_\alpha \approx x_a + (x_b - x_a) \cdot \frac{\alpha - a}{b - a}$$

mit a : größte vertafelte Zahl $< \alpha$
 b : kleinste vertafelte Zahl $> \alpha$

Beispiel: $X \sim N(0; 1)$; $x_{0,6} \approx 0,25 + (0,26 - 0,25) \cdot \frac{0,6 - 0,5987}{0,6026 - 0,5987} = 0,2533$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

$\hat{=}$ arithm. Mittel in deskript. Statistik

d) Erwartungswert $E(X)$ bzw. μ :

$$E(X) = \begin{cases} \sum_i x_i f(x_i), & \text{falls } X \text{ diskret} \\ \int_{-\infty}^{\infty} x f(x) dx, & \text{falls } X \text{ stetig} \end{cases}$$

Beispiel: Diskrete Verteilung mit

| | | | |
|--------|---------------|---------------|---------------|
| x | 0 | 1 | 2 |
| $f(x)$ | $\frac{1}{4}$ | $\frac{1}{2}$ | $\frac{1}{4}$ |

$$\Rightarrow E(X) = 0 \cdot \frac{1}{4} + 1 \cdot \frac{1}{2} + 2 \cdot \frac{1}{4} = 1$$

Beispiel: Für eine **exponentialverteilte** Zufallsvariable X mit der Dichte

$$f(x) = \begin{cases} \lambda \cdot e^{-\lambda x} & \text{für } x \geq 0 \\ 0 & \text{sonst} \end{cases} \quad \text{folgt}$$

$$\begin{aligned} E(X) &= \int_{-\infty}^{\infty} x \cdot f(x) dx = \lambda \int_0^{\infty} x \cdot e^{-\lambda x} dx = \lambda \left[-\frac{1}{\lambda} x e^{-\lambda x} - \int_0^{\infty} 1 \cdot \left(-\frac{1}{\lambda} e^{-\lambda x} \right) dx \right] \\ &= -x e^{-\lambda x} - \frac{1}{\lambda} e^{-\lambda x} \Big|_0^{\infty} = -0 - \left(-0 - \frac{1}{\lambda} \right) = \frac{1}{\lambda} \end{aligned}$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
 - Kombinatorik
 - Zufall und Wahrscheinlichkeit
 - Zufallsvariablen und Verteilungen
 - Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

- ▶ Ist f **symmetrisch** bzgl. a , so gilt $E(X) = a$
Beispiel: f der Gleichverteilung symmetrisch
bzgl. $\frac{a+b}{2} \Rightarrow E(X) = \frac{a+b}{2}$

- ▶ Lineare Transformation:

$$E(a + bX) = a + b \cdot E(X)$$

- ▶ Summenbildung:

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

Beispiel: X gleichverteilt in $[0; 10]$, $Y \sim N(1; 1)$; $Z = X + 5Y$

$$E(Z) = E(X + 5Y) = E(X) + E(5Y) = E(X) + 5 \cdot E(Y) = \frac{10+0}{2} + 5 \cdot 1 = 10$$

- ▶ Unabhängigkeit:

$$X, Y \text{ unabhängig} \Rightarrow E(X \cdot Y) = E(X) \cdot E(Y)$$

deskr.: mittlere quadr.
 Abweichung

$$\frac{1}{n} \sum (x_i - \bar{x})^2 = s^2$$

► **Varianz** $\text{Var}(X)$ bzw. σ^2 :

$$\text{Var}(X) = E([X - E(X)]^2) = \begin{cases} \sum_i [x_i - E(X)]^2 f(x_i), & \text{wenn } X \text{ diskret} \\ \int_{-\infty}^{\infty} [x - E(X)]^2 f(x) dx, & \text{wenn } X \text{ stetig} \end{cases}$$

► **Standardabweichung** $\text{Sta}(X)$ bzw. σ :

$$\text{Sta}(X) = \sqrt{\text{Var}(X)}$$

Beispiel: Diskrete Verteilung

| | | | | |
|--------|---------------|---------------|---------------|---|
| x | 0 | 1 | 2 | : |
| $f(x)$ | $\frac{1}{4}$ | $\frac{1}{2}$ | $\frac{1}{4}$ | |

$$\text{Var}(X) = (0 - 1)^2 \cdot \frac{1}{4} + (1 - 1)^2 \cdot \frac{1}{2} + (2 - 1)^2 \cdot \frac{1}{4} = \frac{1}{2}$$

Beispiel: Für eine **exponentialverteilte** Zufallsvariable X (Dichte siehe Erwartungswert) folgt

$$\begin{aligned} \text{Var}(X) &= \int_{-\infty}^{\infty} (x - E(X))^2 f(x) dx = \lambda \int_0^{\infty} \left(x - \frac{1}{\lambda}\right)^2 \cdot e^{-\lambda x} dx \\ &= e^{-\lambda x} \left(-x^2 + \frac{2x}{\lambda} - \left(\frac{1}{\lambda}\right)^2 - \frac{2}{\lambda^2} - \frac{2x}{\lambda} + \frac{2x^2}{\lambda^2}\right) \Big|_0^{\infty} \\ &= 0 - \left(-0^2 - \left(\frac{1}{\lambda}\right)^2\right) = \frac{1}{\lambda^2} \end{aligned}$$



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
 Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse

► Verschiebungssatz:

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

Beispiel: Diskrete Verteilung

| | | | | |
|------|---------------|---------------|---------------|---|
| x | 0 | 1 | 2 | |
| f(x) | $\frac{1}{4}$ | $\frac{1}{2}$ | $\frac{1}{4}$ | : |

$$\begin{aligned} E(X^2) &= 0^2 \cdot \frac{1}{4} + 1^2 \cdot \frac{1}{2} + 2^2 \cdot \frac{1}{4} \\ &= \frac{3}{2} \end{aligned}$$

$$\Rightarrow E(X^2) - [E(X)]^2 = \frac{3}{2} - 1^2 = \frac{1}{2} = \text{Var}(X)$$

► Lineare Transformation:

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

► **Summenbildung** gilt nur, wenn die X_i unabhängig! Dann:

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



| Verteilung von X | $E(X)$ | $\text{Var}(X)$ |
|--|-------------------|---|
| Binomialverteilung $B(n; p)$ | np | $np(1 - p)$ |
| Hypergeometrische Verteilung mit den Parametern N, M, n | $n \frac{M}{N}$ | $n \frac{M}{N} \frac{N-M}{N} \frac{N-n}{N-1}$ |
| Poisson-Verteilung $P(\lambda)$ | λ | λ |
| Gleichverteilung in $[a; b]$ mit $a < b$ | $\frac{a + b}{2}$ | $\frac{(b - a)^2}{12}$ |
| Normalverteilung $N(\mu; \sigma)$ | μ | σ^2 |

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse



- ▶ Für beliebige Zufallsvariablen X und $\varepsilon > 0$ gilt die **Ungleichung von Tschebyschow**:

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

Beispiele:

- ▶ X ist gleichverteilt mit Parametern a, b und $\varepsilon = \frac{1}{3}(a - b)$,
also $E[X] = \frac{1}{2}(a + b)$ und $\text{Var}[X] = \frac{1}{12}(a - b)^2$
$$\Rightarrow P(|X - \frac{1}{2}(a + b)| \geq \frac{1}{3}(a - b)) \leq \frac{(a - b)^2}{12} \cdot \frac{3^2}{(a - b)^2} = 3/4$$
- ▶ $X \sim B(100; 0,2)$ und $\varepsilon = 10$
damit: $E[X] = 100 \cdot 0,2 = 20$ und $\text{Var}[X] = 100 \cdot 0,2 \cdot (1 - 0,2) = 16$
$$\Rightarrow P(|X - 20| \geq 10) \leq \frac{16}{10^2} = 0,16$$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und
Verteilungen

Verteilungsparameter

4. Induktive Statistik

5. Datenanalyse


desk. Stat.
$$\text{Cov.} = \frac{1}{n} \sum (x_i - \bar{x})(y_i - \bar{y})$$

► Kovarianz:

$$\begin{aligned}\text{Cov}(X, Y) &= E[(X - E(X))(Y - E(Y))] \\ &= E(X \cdot Y) - E(X) \cdot E(Y) \\ &\text{(Verschiebungssatz)}\end{aligned}$$

► Korrelationskoeffizient:

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



► Bemerkungen:

- ρ ist r nachgebildet $\Rightarrow \rho \in [-1; 1]$
- $|\rho| = 1 \iff Y = a + bX$ (mit $b \neq 0$)
- $\rho = 0 \iff X, Y$ **unkorreliert**


► Varianz einer Summe zweier ZV:

$$\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y) + 2 \text{Cov}(X, Y)$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
Kombinatorik
Zufall und Wahrscheinlichkeit
Zufallsvariablen und Verteilungen
Verteilungsparameter
4. Induktive Statistik
5. Datenanalyse

- 1 Statistik: Einführung
- 2 Deskriptive Statistik
- 3 Wahrscheinlichkeitstheorie
- 4 Induktive Statistik
- 5 Datenanalyse Einleitung



- 4 Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests



- ▶ Vollerhebung of unmöglich,
- ▶ Deshalb: Beobachte Teilgesamtheit und schließe auf Grundgesamtheit

Beispiel

Warensendung von 1000 Stück; darunter M Stück Ausschuss.
 M ist unbekannt.

→ Zufällige Entnahme von $n = 30$ Stück („Stichprobe“).
Darunter 2 Stück Ausschuss.

Denkbare Zielsetzungen:

- ▶ Schätze M durch eine Zahl (z.B. $\frac{2}{30} \cdot 1000 = 66,67$)
- ▶ Schätze ein Intervall für M (z.B. $M \in [58; 84]$)
- ▶ Teste die Hypothese, dass $M > 50$ ist.

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



- ▶ **Grundgesamtheit (G):** Menge aller relevanten Merkmalsträger.
- ▶ **Verteilung von G:** $F(x) = P(X \leq x)$ = Wahrscheinlichkeit, dass ein Merkmalsträger ausgewählt wird, der beim untersuchten Merkmal maximal die Ausprägung x aufweist.
- ▶ **Uneingeschränkte (reine) Zufallsauswahl:**
Jedes Element von G hat die selbe Chance, ausgewählt zu werden.
- ▶ **Stichprobenumfang (n):** Anzahl der Merkmalsträger in der Stichprobe.
- ▶ **Einfache Stichprobe:**
Uneingeschränkte Zufallsauswahl und unabhängige Ziehung.
→ Alle **Stichprobenvariablen** X_1, \dots, X_n sind iid.
- ▶ **Stichprobenergebnis:**
*independent
identical
distributed*
 n -Tupel der Realisationen der Stichprobenvariablen, (x_1, \dots, x_n) .

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik

Grundlagen

- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests

5. Datenanalyse

- Gegeben: Einfache Stichprobe X_1, \dots, X_n , Beliebige Verteilung,
mit $E(X_i) = \mu$, $\text{Var}(X_i) = \sigma^2$

| Stichprobenfunktion V | Bezeichnung | $E(V)$ | $\text{Var}(V)$ |
|--|--|--------------------------|----------------------|
| $\sum_{i=1}^n X_i$ | Merkmalssumme | $n\mu$ | $n\sigma^2$ |
| $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ | Stichprobenmittel | μ | $\frac{\sigma^2}{n}$ |
| $\frac{\bar{X} - \mu}{\sigma} \sqrt{n}$ | Gauß-Statistik | 0 | 1 |
| $\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$ | mittlere quadratische Abweichung bezüglich μ | σ^2 | |
| $\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ | mittlere quadratische Abweichung | $\frac{n-1}{n} \sigma^2$ | |
| $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ | Stichprobenvarianz | σ^2 | |
| $S = \sqrt{S^2}$ | Stichproben-Standardabweichung | | |
| $\frac{\bar{X} - \mu}{S} \sqrt{n}$ | t-Statistik | | |







sla(v)





1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse

$\frac{\sigma}{\sqrt{n}}$

Ziehen von 10.000 Stichproben (jeweils vom Umfang n) und Berechnung der Stichprobenmittel (Verteilung: zwei überlagerte Gleichverteilungen):



1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
- Grundlagen
- Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik





Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse




1. Einführung
 2. Deskriptive Statistik
 3. W-Theorie
 4. Induktive Statistik
- Grundlagen
- Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse

Chi-Quadrat-Verteilung

- Sind X_1, \dots, X_n iid $N(0; 1)$ -verteilte Zufallsvariablen, so wird die Verteilung von

$$Z = \sum_{i=1}^n X_i^2$$

als **Chi-Quadrat-Verteilung mit n Freiheitsgraden** bezeichnet.



- Kurzschreibweise: $Z \sim \chi^2(n)$
- **Beispiel:** $\chi^2(30)$: $x_{0,975} = 46,98$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse

Quantiltabelle der χ^2 -Verteilung mit n Freiheitsgraden



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

| $\alpha \setminus n$ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 |
|----------------------|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| 0.005 | 0.00 | 0.01 | 0.07 | 0.21 | 0.41 | 0.68 | 0.99 | 1.34 | 1.73 | 2.16 | 2.60 | 3.07 | 3.56 | 4.07 | 4.60 |
| 0.01 | 0.00 | 0.02 | 0.11 | 0.30 | 0.55 | 0.87 | 1.24 | 1.65 | 2.09 | 2.56 | 3.05 | 3.57 | 4.11 | 4.66 | 5.23 |
| 0.025 | 0.00 | 0.05 | 0.22 | 0.48 | 0.83 | 1.24 | 1.69 | 2.18 | 2.70 | 3.25 | 3.82 | 4.40 | 5.01 | 5.63 | 6.26 |
| 0.05 | 0.00 | 0.10 | 0.35 | 0.71 | 1.15 | 1.64 | 2.17 | 2.73 | 3.33 | 3.94 | 4.57 | 5.23 | 5.89 | 6.57 | 7.26 |
| 0.1 | 0.02 | 0.21 | 0.58 | 1.06 | 1.61 | 2.20 | 2.83 | 3.49 | 4.17 | 4.87 | 5.58 | 6.30 | 7.04 | 7.79 | 8.55 |
| 0.2 | 0.06 | 0.45 | 1.01 | 1.65 | 2.34 | 3.07 | 3.82 | 4.59 | 5.38 | 6.18 | 6.99 | 7.81 | 8.63 | 9.47 | 10.31 |
| 0.25 | 0.10 | 0.58 | 1.21 | 1.92 | 2.67 | 3.45 | 4.25 | 5.07 | 5.90 | 6.74 | 7.58 | 8.44 | 9.30 | 10.17 | 11.04 |
| 0.4 | 0.28 | 1.02 | 1.87 | 2.75 | 3.66 | 4.57 | 5.49 | 6.42 | 7.36 | 8.30 | 9.24 | 10.18 | 11.13 | 12.08 | 13.03 |
| 0.5 | 0.45 | 1.39 | 2.37 | 3.36 | 4.35 | 5.35 | 6.35 | 7.34 | 8.34 | 9.34 | 10.34 | 11.34 | 12.34 | 13.34 | 14.34 |
| 0.6 | 0.71 | 1.83 | 2.95 | 4.04 | 5.13 | 6.21 | 7.28 | 8.35 | 9.41 | 10.47 | 11.53 | 12.58 | 13.64 | 14.69 | 15.73 |
| 0.75 | 1.32 | 2.77 | 4.11 | 5.39 | 6.63 | 7.84 | 9.04 | 10.22 | 11.39 | 12.55 | 13.70 | 14.85 | 15.98 | 17.12 | 18.25 |
| 0.8 | 1.64 | 3.22 | 4.64 | 5.99 | 7.29 | 8.56 | 9.80 | 11.03 | 12.24 | 13.44 | 14.63 | 15.81 | 16.98 | 18.15 | 19.31 |
| 0.9 | 2.71 | 4.61 | 6.25 | 7.78 | 9.24 | 10.64 | 12.02 | 13.36 | 14.68 | 15.99 | 17.27 | 18.55 | 19.81 | 21.06 | 22.31 |
| 0.95 | 3.84 | 5.99 | 7.81 | 9.49 | 11.07 | 12.59 | 14.07 | 15.51 | 16.92 | 18.31 | 19.68 | 21.03 | 22.36 | 23.68 | 25.00 |
| 0.975 | 5.02 | 7.38 | 9.35 | 11.14 | 12.83 | 14.45 | 16.01 | 17.53 | 19.02 | 20.48 | 21.92 | 23.34 | 24.74 | 26.12 | 27.49 |
| 0.99 | 6.63 | 9.21 | 11.34 | 13.28 | 15.09 | 16.81 | 18.48 | 20.09 | 21.67 | 23.21 | 24.73 | 26.22 | 27.69 | 29.14 | 30.58 |
| 0.995 | 7.88 | 10.60 | 12.84 | 14.86 | 16.75 | 18.55 | 20.28 | 21.95 | 23.59 | 25.19 | 26.76 | 28.30 | 29.82 | 31.32 | 32.80 |

| $\alpha \setminus n$ | 16 | 17 | 18 | 19 | 20 | 21 | 22 | 23 | 24 | 25 | 26 | 27 | 28 | 29 | 30 |
|----------------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| 0.005 | 5.14 | 5.70 | 6.26 | 6.84 | 7.43 | 8.03 | 8.64 | 9.26 | 9.89 | 10.52 | 11.16 | 11.81 | 12.46 | 13.12 | 13.79 |
| 0.01 | 5.81 | 6.41 | 7.01 | 7.63 | 8.26 | 8.90 | 9.54 | 10.20 | 10.86 | 11.52 | 12.20 | 12.88 | 13.56 | 14.26 | 14.95 |
| 0.025 | 6.91 | 7.56 | 8.23 | 8.91 | 9.59 | 10.28 | 10.98 | 11.69 | 12.40 | 13.12 | 13.84 | 14.57 | 15.31 | 16.05 | 16.79 |
| 0.05 | 7.96 | 8.67 | 9.39 | 10.12 | 10.85 | 11.59 | 12.34 | 13.09 | 13.85 | 14.61 | 15.38 | 16.15 | 16.93 | 17.71 | 18.49 |
| 0.1 | 9.31 | 10.09 | 10.86 | 11.65 | 12.44 | 13.24 | 14.04 | 14.85 | 15.66 | 16.47 | 17.29 | 18.11 | 18.94 | 19.77 | 20.60 |
| 0.2 | 11.15 | 12.00 | 12.86 | 13.72 | 14.58 | 15.44 | 16.31 | 17.19 | 18.06 | 18.94 | 19.82 | 20.70 | 21.59 | 22.48 | 23.36 |
| 0.25 | 11.91 | 12.79 | 13.68 | 14.56 | 15.45 | 16.34 | 17.24 | 18.14 | 19.04 | 19.94 | 20.84 | 21.75 | 22.66 | 23.57 | 24.48 |
| 0.4 | 13.98 | 14.94 | 15.89 | 16.85 | 17.81 | 18.77 | 19.73 | 20.69 | 21.65 | 22.62 | 23.58 | 24.54 | 25.51 | 26.48 | 27.44 |
| 0.5 | 15.34 | 16.34 | 17.34 | 18.34 | 19.34 | 20.34 | 21.34 | 22.34 | 23.34 | 24.34 | 25.34 | 26.34 | 27.34 | 28.34 | 29.34 |
| 0.6 | 16.78 | 17.82 | 18.87 | 19.91 | 20.95 | 21.99 | 23.03 | 24.07 | 25.11 | 26.14 | 27.18 | 28.21 | 29.25 | 30.28 | 31.32 |
| 0.75 | 19.37 | 20.49 | 21.60 | 22.72 | 23.83 | 24.93 | 26.04 | 27.14 | 28.24 | 29.34 | 30.43 | 31.53 | 32.62 | 33.71 | 34.80 |
| 0.8 | 20.47 | 21.61 | 22.76 | 23.90 | 25.04 | 26.17 | 27.30 | 28.43 | 29.55 | 30.68 | 31.79 | 32.91 | 34.03 | 35.14 | 36.25 |
| 0.9 | 23.54 | 24.77 | 25.99 | 27.20 | 28.41 | 29.62 | 30.81 | 32.01 | 33.20 | 34.38 | 35.56 | 36.74 | 37.92 | 39.09 | 40.26 |
| 0.95 | 26.30 | 27.59 | 28.87 | 30.14 | 31.41 | 32.67 | 33.92 | 35.17 | 36.41 | 37.65 | 38.89 | 40.11 | 41.34 | 42.56 | 43.77 |
| 0.975 | 28.85 | 30.19 | 31.53 | 32.85 | 34.17 | 35.48 | 36.78 | 38.08 | 39.36 | 40.65 | 41.92 | 43.19 | 44.46 | 45.72 | 46.98 |
| 0.99 | 32.00 | 33.41 | 34.81 | 36.19 | 37.57 | 38.93 | 40.29 | 41.64 | 42.98 | 44.31 | 45.64 | 46.96 | 48.28 | 49.59 | 50.89 |
| 0.995 | 34.27 | 35.72 | 37.16 | 38.58 | 40.00 | 41.40 | 42.80 | 44.18 | 45.56 | 46.93 | 48.29 | 49.64 | 50.99 | 52.34 | 53.67 |


- ▶ Ist $X \sim N(0; 1)$, $Z \sim \chi^2(n)$, X , Z unabhängig, so wird die Verteilung von

$$T = \frac{X}{\sqrt{\frac{1}{n} Z}}$$

als **t-Verteilung** mit n Freiheitsgraden bezeichnet.



William Sealy Gosset
1876 – 1937



- ▶ Kurzschreibweise: $T \sim t(n)$
- ▶ **Beispiel:** $t(10)$ $x_{0,6} = 0,260$, $x_{0,5} = 0$, $x_{0,1} = -x_{0,9} = -1,372$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse

Quantiltabelle der t-Verteilung mit n Freiheitsgraden


| $\alpha \setminus n$ | 0.6 | 0.75 | 0.8 | 0.9 | 0.95 | 0.975 | 0.99 | 0.995 |
|----------------------|-------|-------|-------|-------|-------|--------|--------|--------|
| 1 | 0.325 | 1.000 | 1.376 | 3.078 | 6.314 | 12.706 | 31.820 | 63.657 |
| 2 | 0.289 | 0.816 | 1.061 | 1.886 | 2.920 | 4.303 | 6.965 | 9.925 |
| 3 | 0.277 | 0.765 | 0.979 | 1.638 | 2.353 | 3.183 | 4.541 | 5.841 |
| 4 | 0.271 | 0.741 | 0.941 | 1.533 | 2.132 | 2.776 | 3.747 | 4.604 |
| 5 | 0.267 | 0.727 | 0.920 | 1.476 | 2.015 | 2.571 | 3.365 | 4.032 |
| 6 | 0.265 | 0.718 | 0.906 | 1.440 | 1.943 | 2.447 | 3.143 | 3.707 |
| 7 | 0.263 | 0.711 | 0.896 | 1.415 | 1.895 | 2.365 | 2.998 | 3.499 |
| 8 | 0.262 | 0.706 | 0.889 | 1.397 | 1.860 | 2.306 | 2.897 | 3.355 |
| 9 | 0.261 | 0.703 | 0.883 | 1.383 | 1.833 | 2.262 | 2.821 | 3.250 |
| 10 | 0.260 | 0.700 | 0.879 | 1.372 | 1.812 | 2.228 | 2.764 | 3.169 |
| 11 | 0.260 | 0.698 | 0.875 | 1.363 | 1.796 | 2.201 | 2.718 | 3.106 |
| 12 | 0.259 | 0.696 | 0.873 | 1.356 | 1.782 | 2.179 | 2.681 | 3.054 |
| 13 | 0.259 | 0.694 | 0.870 | 1.350 | 1.771 | 2.160 | 2.650 | 3.012 |
| 14 | 0.258 | 0.692 | 0.868 | 1.345 | 1.761 | 2.145 | 2.624 | 2.977 |
| 15 | 0.258 | 0.691 | 0.866 | 1.341 | 1.753 | 2.131 | 2.603 | 2.947 |
| 16 | 0.258 | 0.690 | 0.865 | 1.337 | 1.746 | 2.120 | 2.583 | 2.921 |
| 17 | 0.257 | 0.689 | 0.863 | 1.333 | 1.740 | 2.110 | 2.567 | 2.898 |
| 18 | 0.257 | 0.688 | 0.862 | 1.330 | 1.734 | 2.101 | 2.552 | 2.878 |
| 19 | 0.257 | 0.688 | 0.861 | 1.328 | 1.729 | 2.093 | 2.539 | 2.861 |
| 20 | 0.257 | 0.687 | 0.860 | 1.325 | 1.725 | 2.086 | 2.528 | 2.845 |
| 21 | 0.257 | 0.686 | 0.859 | 1.323 | 1.721 | 2.080 | 2.518 | 2.831 |
| 22 | 0.256 | 0.686 | 0.858 | 1.321 | 1.717 | 2.074 | 2.508 | 2.819 |
| 23 | 0.256 | 0.685 | 0.858 | 1.319 | 1.714 | 2.069 | 2.500 | 2.807 |
| 24 | 0.256 | 0.685 | 0.857 | 1.318 | 1.711 | 2.064 | 2.492 | 2.797 |
| 25 | 0.256 | 0.684 | 0.856 | 1.316 | 1.708 | 2.059 | 2.485 | 2.787 |
| 26 | 0.256 | 0.684 | 0.856 | 1.315 | 1.706 | 2.055 | 2.479 | 2.779 |
| 27 | 0.256 | 0.684 | 0.855 | 1.314 | 1.703 | 2.052 | 2.473 | 2.771 |
| 28 | 0.256 | 0.683 | 0.855 | 1.312 | 1.701 | 2.048 | 2.467 | 2.763 |
| 29 | 0.256 | 0.683 | 0.854 | 1.311 | 1.699 | 2.045 | 2.462 | 2.756 |
| 30 | 0.256 | 0.683 | 0.854 | 1.310 | 1.697 | 2.042 | 2.457 | 2.750 |



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse

Dichtefunktion

- ▶ t-Verteilung mit 1 (blau), 3 (grün) und 10 (lila) Freiheitsgraden
- ▶ Standardnormalverteilung (rot)



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



- ▶ Ein unbekannter Parameter ϑ der Verteilung von G soll auf Basis einer Stichprobe geschätzt werden.
- ▶ Zum Beispiel: σ von $N(10; \sigma)$
- ▶ Schätzwert: $\hat{\vartheta}$
- ▶ Vorgehen: Verwendung einer **Schätzfunktion**

$$\hat{\Theta} = g(X_1, \dots, X_n)$$

Beachte: Der Schätzwert $\hat{\vartheta}$ ist die Realisierung der ZV (!) $\hat{\Theta}$.

- ▶ Frage: Welche Stichprobenfunktion ist zur Schätzung geeignet?
- ▶ Kriterien für die Beurteilung/Konstruktion von Schätzfunktionen!
- ▶ Im Folgenden: Vorliegen einer einfachen Stichprobe, d.h. X_1, \dots, X_n iid.

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

- ▶ Schätzen des Mittelwertes einer Grundgesamtheit
- ▶ dazu: Einfache Stichprobe vom Umfang 5
- ▶ und den beiden Stichprobenfunktionen


$$\hat{\Theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\Theta}_2 = \frac{1}{n-1} \sum_{i=1}^n X_i$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests
5. Datenanalyse

- ▶ Schätzen des Mittelwertes einer Grundgesamtheit
- ▶ dazu: Einfache Stichprobe vom Umfang 5
- ▶ und den beiden Stichprobenfunktionen


$$\hat{\Theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\Theta}_2 = \frac{1}{n-1} \sum_{i=1}^n X_i$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests
5. Datenanalyse

- ▶ Schätzen des Mittelwertes einer Grundgesamtheit
- ▶ dazu: Einfache Stichprobe vom Umfang 5
- ▶ und den beiden Stichprobenfunktionen


$$\hat{\Theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\Theta}_2 = \frac{1}{n-1} \sum_{i=1}^n X_i$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests
5. Datenanalyse

- ▶ Schätzen des Mittelwertes einer Grundgesamtheit
- ▶ dazu: Einfache Stichprobe vom Umfang 5
- ▶ und den beiden Stichprobenfunktionen


$$\hat{\Theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\Theta}_2 = \frac{1}{n-1} \sum_{i=1}^n X_i$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests
5. Datenanalyse

- ▶ Schätzen des Mittelwertes einer Grundgesamtheit
- ▶ dazu: Einfache Stichprobe vom Umfang 5
- ▶ und den beiden Stichprobenfunktionen

$$\hat{\Theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\Theta}_2 = \frac{1}{n-1} \sum_{i=1}^n X_i$$




1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests
5. Datenanalyse



- ▶ Schätzen des Mittelwertes einer Grundgesamtheit
- ▶ dazu: Einfache Stichprobe vom Umfang 5
- ▶ und den beiden Stichprobenfunktionen

$$\hat{\Theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\Theta}_2 = \frac{1}{n-1} \sum_{i=1}^n X_i$$



Mittelwert Grundgesamtheit = 4.53

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse

- Eine Schätzfunktion $\hat{\Theta} = g(X_1, \dots, X_n)$ heißt **erwartungstreu** oder **unverzerrt** für ϑ , wenn unabhängig vom numerischen Wert von ϑ gilt:

$$E(\hat{\Theta}) = \vartheta$$

Beispiel

Sind $\hat{\Theta}_1 = \bar{X}$, $\hat{\Theta}_2 = \frac{X_1 + X_n}{2}$, $\hat{\Theta}_3 = \frac{1}{n-1} \sum_{i=1}^n X_i$ erwartungstreu für μ ?

- a) $\hat{\Theta}_1$: $E(\bar{X}) = \mu$
 $\Rightarrow \hat{\Theta}_1$ ist erwartungstreu.
- b) $\hat{\Theta}_2$: $E\left(\frac{X_1 + X_n}{2}\right) = \frac{1}{2}[E(X_1) + E(X_n)] = \frac{1}{2}(\mu + \mu) = \mu$
 $\Rightarrow \hat{\Theta}_2$ ist erwartungstreu.
- c) $\hat{\Theta}_3$: $E\left(\frac{1}{n-1} \sum_{i=1}^n X_i\right) = \frac{1}{n-1} \sum_{i=1}^n E(X_i) = \frac{1}{n-1} \sum_{i=1}^n \mu = \frac{n}{n-1} \mu \neq \mu$
 $\Rightarrow \hat{\Theta}_3$ ist nicht erwartungstreu



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests
5. Datenanalyse



- ▶ Welche der erwartungstreuen Schätzfunktionen $\hat{\Theta}_1, \hat{\Theta}_2$ ist „besser“?
- ▶ Von zwei erwartungstreuen Schätzfunktionen $\hat{\Theta}_1, \hat{\Theta}_2$ für ϑ heißt $\hat{\Theta}_1$ **wirksamer** als $\hat{\Theta}_2$, wenn unabhängig vom numerischen Wert von ϑ gilt:

$$\text{Var}(\hat{\Theta}_1) < \text{Var}(\hat{\Theta}_2)$$

Beispiel: ($\hat{\Theta}_1 = \bar{X}$, $\hat{\Theta}_2 = \frac{X_1 + X_n}{2}$)

Wegen

$$\left. \begin{aligned} \text{Var}(\hat{\Theta}_1) &= \text{Var}(\bar{X}) &&= \frac{\sigma^2}{n} \\ \text{Var}(\hat{\Theta}_2) &= \text{Var}\left(\frac{X_1 + X_n}{2}\right) = \frac{1}{4}(\sigma^2 + \sigma^2) = \frac{\sigma^2}{2} \end{aligned} \right\} \Rightarrow \text{Var}(\hat{\Theta}_1) < \text{Var}(\hat{\Theta}_2)$$

(falls $n > 2$) ist $\hat{\Theta}_1$ wirksamer als $\hat{\Theta}_2$.

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



- ▶ Für einen unbekanntem Verteilungsparameter ϑ soll auf Basis einer Stichprobe ein Intervall geschätzt werden.
- ▶ Verwendung der Stichprobenfunktionen V_u, V_o , so dass $V_u \leq V_o$ und

$$P(V_u \leq \vartheta \leq V_o) = 1 - \alpha$$

stets gelten.

$[V_u; V_o]$ heißt **Konfidenzintervall** (KI) für ϑ zum **Konfidenzniveau** $1 - \alpha$. *meist groß, z.B. 95%*

- ▶ Beachte: Das **Schätzintervall** $[v_u; v_o]$ ist Realisierung der Zufallsvariablen (!) V_u, V_o .
 - ➡ Irrtumswahrscheinlichkeit α (klein, i.d.R. $\alpha \leq 0,1$)
- ▶ Frage: Welche Konfidenzintervalle sind zur Schätzung geeignet?
 - ➡ Hängt von Verteilung von G sowie vom unbekanntem Parameter (μ, σ^2) ab!
- ▶ Im Folgenden: Einfache Stichprobe X_1, \dots, X_n mit $E(X_i) = \mu, \text{Var}(X_i) = \sigma^2$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests


5. Datenanalyse



Wichtiger Spezialfall: **Symmetrische Konfidenzintervalle**

- ▶ Symmetrisch heißt **nicht**, dass die Dichte symmetrisch ist, sondern
- ▶ übereinstimmende Wahrscheinlichkeiten für Über-/Unterschreiten des Konfidenzintervalls, d.h.

$$P(V_u > \vartheta) = P(V_o < \vartheta) = \frac{\alpha}{2}$$



- ▶ **Wichtig:** Eine Verkleinerung von α bewirkt eine Vergrößerung des Konfidenzintervalls.

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik


Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



Vorgehensweise:

- 1 Festlegen des Konfidenzniveaus $1 - \alpha$
- 2 Bestimmung des $\left(1 - \frac{\alpha}{2}\right)$ -Fraktils c der $N(0, 1)$ -Verteilung
- 3 Berechnen des Stichprobenmittels \bar{x}
- 4 Berechnen des Wertes $\frac{\sigma c}{\sqrt{n}}$
- 5 Ergebnis der Intervall-Schätzung:

$$\left[\bar{x} - \frac{\sigma c}{\sqrt{n}} ; \bar{x} + \frac{\sigma c}{\sqrt{n}} \right]$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse

Beispiel

Normalverteilung mit $\sigma = 2,4$

$(x_1, \dots, x_9) = (184.2, 182.6, 185.3, 184.5, 186.2, 183.9, 185.0, 187.1, 184.4)$

Gesucht: Konfidenzintervall für μ zum Konfidenzniveau

$1 - \alpha = 0,99$

1. $1 - \alpha = 0,99$
2. $N(0; 1)$: $c = x_{1-\frac{\alpha}{2}} = x_{1-\frac{0,01}{2}} = x_{0,995} = 2,576$ (Tab. 3; Interpolation)
3. $\bar{x} = \frac{1}{9} (184,2 + \dots + 184,4) = 184,8$
4. $\frac{\sigma c}{\sqrt{n}} = \frac{2,4 \cdot 2,576}{\sqrt{9}} = 2,06$
5. $KI = [184,8 - 2,06; 184,8 + 2,06] = [182,74; 186,86]$

Interpretation: Mit 99% Wahrscheinlichkeit ist $\mu \in [182,74; 186,86]$.



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests
5. Datenanalyse



Wichtige $N(0;1)$ -Fraktilewerte:

| α | χ_{α} |
|----------|-----------------|
| 0,9 | 1,281552 |
| 0,95 | 1,644854 |
| 0,975 | 1,959964 |
| 0,99 | 2,326348 |
| 0,995 | 2,575829 |

(I.d.R. genügen drei Nachkommastellen.)

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse

- ▶ Bei bekannter Standardabweichung gilt offenkundig

$$L = V_o - V_u = \frac{2\sigma c}{\sqrt{n}}$$

- ▶ Welcher Stichprobenumfang n sichert eine vorgegebene (Maximal-)Länge L ? \Rightarrow Nach n auflösen! \Rightarrow

$$n \geq \left(\frac{2\sigma c}{L} \right)^2$$

- ▶ Eine Halbierung von L erfordert eine Vervierfachung von n !
- ▶ Angewendet auf letztes **Beispiel**:

$$L = 4 \Rightarrow n \geq \left(\frac{2 \cdot 2,4 \cdot 2,576}{4} \right)^2 = 9,556 \Rightarrow n \geq 10$$

$$L = 2 \Rightarrow n \geq \left(\frac{2 \cdot 2,4 \cdot 2,576}{2} \right)^2 = 38,222 \Rightarrow n \geq 39$$



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

Konfidenzintervall für μ bei Normalverteilung mit unbekanntem σ^2

► Vorgehensweise:

- 1 Festlegen des Konfidenzniveaus $1 - \alpha$
- 2 Bestimmung des $\left(1 - \frac{\alpha}{2}\right)$ -Fraktils c der $t(n - 1)$ -Verteilung
- 3 Berechnen des Stichprobenmittels \bar{x} und der Stichproben-Standardabweichung s
- 4 Berechnen des Wertes $\frac{sc}{\sqrt{n}}$
- 5 Ergebnis der Intervall-Schätzung:

$$\left[\bar{x} - \frac{sc}{\sqrt{n}} ; \bar{x} + \frac{sc}{\sqrt{n}} \right]$$

- Zu Schritt 2: Falls $n - 1 > 30$ wird die $N(0; 1)$ -Verteilung verwendet.



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



Beispiel:

Wie das letzte Beispiel, jedoch σ unbekannt.

- 1 $1 - \alpha = 0,99$
- 2 $t(8): c = x_{1-\frac{\alpha}{2}} = x_{1-\frac{0,01}{2}} = x_{0,995} = 3,355$ (Tab. 4)
- 3 $\bar{x} = \frac{1}{9} (184,2 + \dots + 184,4) = 184,8$
 $s = \sqrt{\frac{1}{8} [(184,2^2 + \dots + 184,4^2) - 9 \cdot 184,8^2]} = 1,31$
- 4 $\frac{sc}{\sqrt{n}} = \frac{1,31 \cdot 3,355}{\sqrt{9}} = 1,47$
- 5 $KI = [184,8 - 1,47; 184,8 + 1,47] = [183,33; 186,27]$

Interpretation: Mit 99% Wahrscheinlichkeit ist $\mu \in [183,33; 186,27]$.

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



```
x <- c(184.2, 182.6, 185.3, 184.5, 186.2,  
       183.9, 185.0, 187.1, 184.4)  
t.test(x, conf.level=.99)  
  
##  
## One Sample t-test  
##  
## data: x  
## t = 422.1129, df = 8, p-value < 2.2e-16  
## alternative hypothesis: true mean is not equal to 0  
## 99 percent confidence interval:  
## 183.331 186.269  
## sample estimates:  
## mean of x  
## 184.8
```

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse



► Voraussetzung: $n > 30$, bzw. falls G dichotom: $5 \leq \sum_{i=1}^n x_i \leq n - 5$

► Vorgehensweise:

- 1 Festlegen des Konfidenzniveaus $1 - \alpha$
- 2 Bestimmung des $(1 - \frac{\alpha}{2})$ -Fraktils c der Standardnormalverteilung $N(0; 1)$
- 3 Berechnung des Stichprobenmittels \bar{x} sowie eines Schätzwertes $\hat{\sigma}$ für die Standardabweichung σ der GG mittels

$$\hat{\sigma} = \begin{cases} \sigma, & \text{falls } \sigma \text{ bekannt} \\ \sqrt{\bar{x}(1 - \bar{x})}, & \text{falls GG dichotom} \\ s, & \text{sonst} \end{cases}$$

- 4 Berechnung von $\frac{\hat{\sigma}c}{\sqrt{n}}$
- 5 Ergebnis der Intervallschätzung:

$$\left[\bar{x} - \frac{\hat{\sigma}c}{\sqrt{n}}; \bar{x} + \frac{\hat{\sigma}c}{\sqrt{n}} \right]$$

► Zu Schritt 3: Manchmal kann anderer Schätzwert $\hat{\sigma}$ sinnvoller sein.

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



Beispiel:

Poisson-Verteilung mit λ ($= \mu = \sigma^2$) unbekannt.

$$(x_1, \dots, x_{40}) = (3; 8; \dots; 6)$$

Gesucht: KI für λ zum Konfidenzniveau $1 - \alpha = 0,9$

1 $1 - \alpha = 0,9$

2 $N(0; 1) : c = x_{1 - \frac{\alpha}{2}} = x_{1 - \frac{0,1}{2}} = x_{0,95} = 1,645$

3 $\bar{x} = \frac{1}{40} (3 + 8 + \dots + 6) = 6,5$

$$\hat{\sigma} = \sqrt{\bar{x}} = \sqrt{6,5} = 2,55 \quad (\text{da } \sigma^2 = \lambda)$$

4 $\frac{\hat{\sigma}c}{\sqrt{n}} = \frac{2,55 \cdot 1,645}{\sqrt{40}} = 0,66$

5 $KI = [6,5 - 0,66; 6,5 + 0,66] = [5,84; 7,16]$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



Vorgehensweise

- 1 Festlegen eines Konfidenzniveaus $1 - \alpha$
- 2 Bestimmung der $\frac{\alpha}{2}$ - bzw. $(1 - \frac{\alpha}{2})$ -Fraktile (c_1 bzw. c_2) der $\chi^2(n - 1)$ -Verteilung
- 3 Aus der Stichprobe: Berechnung der Größe

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

- 4 Berechnung des Konfidenzintervalls

$$\left[\frac{(n - 1)s^2}{c_2}; \frac{(n - 1)s^2}{c_1} \right]$$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



Beispiel:

$$G \sim N(\mu; \sigma);$$

$$(x_1, \dots, x_5) = (1, 1.5, 2.5, 3, 2)$$

Gesucht: KI für σ^2 zum Konfidenzniveau $1 - \alpha = 0,99$

① $1 - \alpha = 0,99$

② $\chi^2(5 - 1) : c_1 = \chi_{\frac{\alpha}{2}} = \chi_{0,005} = 0,21$

$$c_2 = \chi_{1 - \frac{\alpha}{2}} = \chi_{0,995} = 14,86$$

③ $\bar{x} = \frac{1}{5} (1 + 1,5 + 2,5 + 3 + 2) = 2$

$$\sum_{i=1}^5 x_i^2 - 5 \cdot \bar{x}^2 = 1^2 + 1,5^2 + 2,5^2 + 3^2 + 2^2 - 5 \cdot 2^2 = 2,5$$

④ $KI = \left[\frac{2,5}{14,86}; \frac{2,5}{0,21} \right] = [0,17; 11,9]$

(Extrem groß, da n klein.)

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



- ▶ Vorliegen einer **Hypothese** über die Verteilung(en) der Grundgesamtheit(en).
- ▶ Beispiele:
 - „Der Würfel ist fair.“
 - „Die Brenndauern zweier unterschiedlicher Glühbirnensorten sind gleich.“
- ▶ Hypothese soll anhand einer Stichprobe überprüft werden.
- ▶ Prinzip:
 - **Hypothese verwerfen**, wenn „signifikanter“ Widerspruch zur Stichprobe.
 - Ansonsten: **Hypothese nicht verwerfen**.
- ▶ Eine verworfene Hypothese gilt als statistisch widerlegt.
- ▶ Nicht-Verwerfung ist dagegen ein „Freispruch aus Mangel an Beweisen“.

Zu Beachten:

Nicht-Verwerfung ist **kein** „statistischer Beweis“, dass Hypothese wahr ist!
(„Trick“: Hypothese falsch \iff Gegenhypothese wahr!)

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- 5. Datenanalyse



► Zunächst:

- $G \sim N(\mu; \sigma)$ mit σ bekannt
- Einfache Stichprobe X_1, \dots, X_n
- (Null-)Hypothese $H_0 : \mu = \mu_0$

► **Beispiel:**

X_1, \dots, X_{25} mit $X_i =$ Füllmenge der i -ten Flasche $\sim N(\mu; 1,5)$

Nullhypothese $H_0 : \mu = 500$, d.h. $\mu_0 = 500$

► Je nach Interessenlage sind unterschiedliche **Gegenhypothesen** möglich:

- a) $H_1 : \mu \neq \mu_0$
- b) $H_1 : \mu < \mu_0$
- c) $H_1 : \mu > \mu_0$

► Entscheidung:

- $H_0 : \mu = \mu_0$ wird abgelehnt gegenüber
- a) $H_1 : \mu \neq \mu_0$, wenn $|\bar{x} - \mu_0|$ „sehr groß“ ist
 - b) $H_1 : \mu < \mu_0$, wenn \bar{x} „weit kleiner“ als μ_0 ist
 - c) $H_1 : \mu > \mu_0$, wenn \bar{x} „weit größer“ als μ_0 ist

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

Test des Erwartungswertes bei bekannter Varianz in der Grundgesamtheit

Entscheidungskriterium aus Stichprobe:

$$v = \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n}$$

► Vorteil: Verteilung bekannt: $N(0; 1)$



► Dann:

$H_0 : \mu = \mu_0$ wird abgelehnt gegenüber

- a) $H_1 : \mu \neq \mu_0$, wenn $|v|$ „sehr groß“ ist
- b) $H_1 : \mu < \mu_0$, wenn v „sehr negativ“ ist
- c) $H_1 : \mu > \mu_0$, wenn v „sehr positiv“ ist

Mögliche Fehlentscheidungen

- **Ablehnung von H_0** , obwohl H_0 richtig ist: **Fehler 1. Art**
- **Nicht-Ablehnung von H_0** , obwohl H_0 falsch ist: **Fehler 2. Art**



► **Signifikanzniveau α** : Maximal erlaubte Wahrscheinlichkeit für einen Fehler 1. Art.



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests
- 5. Datenanalyse



- ▶ Mithilfe von α und V kann geklärt werden, was „sehr groß“ usw. heißt:

Wahrscheinlichkeit für Fehler 1. Art im Fall

a): $|v| > x$, obwohl H_0 richtig:

$$\begin{aligned} P(|V| > x) &= P(V > x) + P(V < -x) \\ &= 2 \cdot P(V > x) \quad (\text{Symmetrie der Normalverteilung}) \end{aligned}$$


$$= 2 \cdot [1 - P(V \leq x)] = 2 \cdot [1 - \Phi(x)] \stackrel{!}{=} \alpha$$

$$\Leftrightarrow \Phi(x) = 1 - \frac{\alpha}{2}$$

$$\Leftrightarrow x = x_{1 - \frac{\alpha}{2}}$$

H_0 wird demnach verworfen,
wenn $|v| > x_{1 - \frac{\alpha}{2}}$ bzw. $v \in B$ ist.

$B = (-\infty; -x_{1 - \frac{\alpha}{2}}) \cup (x_{1 - \frac{\alpha}{2}}; \infty)$ heißt **Verwerfungsbereich**.



- ▶ Analoge Vorgehensweise für die Fälle b) und c)

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse



Rezept

- 1 Ein Signifikanzniveau α wird festgelegt.
- 2 Der Verwerfungsbereich

$$B = (-\infty; -x_{1-\alpha/2}) \cup (x_{1-\alpha/2}; \infty) \quad \text{im Fall a)}$$

$$B = (-\infty; -x_{1-\alpha}) \quad \text{im Fall b)}$$

$$B = (x_{1-\alpha}; \infty) \quad \text{im Fall c)}$$

wird festgelegt, wobei $x_{1-\alpha/2}$ bzw. $x_{1-\alpha}$ das $(1 - \alpha/2)$ - bzw. das $(1 - \alpha)$ -Fraktile der $N(0,1)$ -Verteilung ist. (**Wichtig:** Der Ablehnungsbereich ist also unabhängig von der Stichprobe)

- 3 **Wichtig:** Erst jetzt werden die Daten der Stichprobe erhoben/beachtet:

Der Testfunktionswert $v = \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n}$ wird berechnet.

- 4 H_0 wird genau dann verworfen, wenn $v \in B$ gilt.

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse



Beispiel:

X_1, \dots, X_{25} mit $X_i \sim N(\mu; 1,5)$ und $\bar{x} = 499,28$

Prüfe $H_0 : \mu = 500$, $H_1 : \mu \neq 500$ zum Signifikanzniveau $\alpha = 0,01$

Lösung: Einstichproben-Gaußtest, Fall a)

- 1 $\alpha = 0,01$
- 2 $N(0; 1) : \chi_{1-\frac{\alpha}{2}} = \chi_{1-0,005} = \chi_{0,995} = 2,576$
 $\Rightarrow B = (-\infty; -2,576) \cup (2,576; \infty)$
- 3 $v = \frac{499,28-500}{1,5} \cdot \sqrt{25} = -2,4$
- 4 $v \notin B \Rightarrow H_0$ nicht verwerfen

Interpretation: Zum Signifikanzniveau 1 % kann der Brauerei keine Abweichung vom Sollwert $\mu_0 = 500$ nachgewiesen werden.

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

Der jeweils geeignete Test hängt ab von ...

- ▶ dem zu testenden Hypothesenpaar H_0, H_1 ; unterscheide:
 - **Parametrische Hypothesen:**
Beziehen sich auf unbekannte(n)
Verteilungsparameter (μ, σ^2, \dots)
 - **Nichtparametrische Hypothesen:**
Beinhalten sonstige Aussagen, z.B. „Alter und Einkommen sind unabh.“
- ▶ den Voraussetzungen an die Verteilung/parameter
(z.B. $G \sim N(\mu; \sigma)$)
- ▶ den Voraussetzungen an den Stichprobenumfang
(z.B. $n > 30$)
- ▶ Art und Anzahl der Stichproben; unterscheide:
 - Signifikanztests bei einer **einfachen Stichprobe**
 - Signifikanztests bei **mehreren unabhängigen Stichproben**
 - Signifikanztests bei **zwei verbundenen Stichproben**

In dieser Vorlesung: Nur **einfache Stichproben**



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

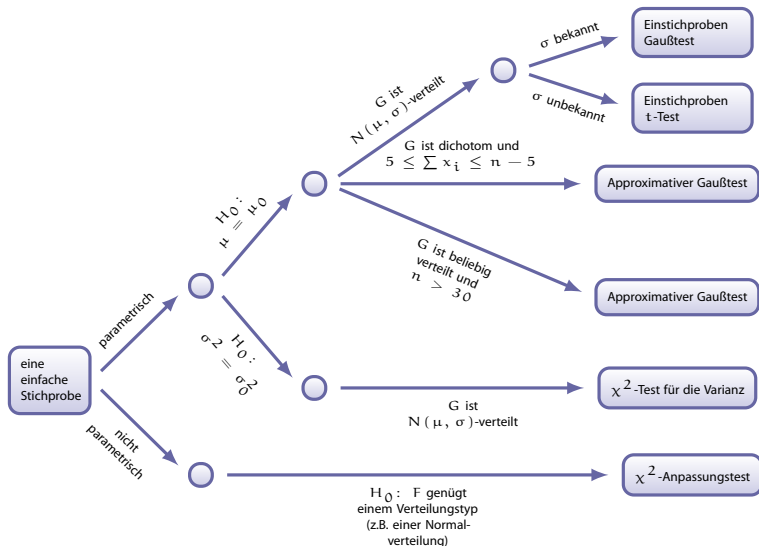
Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

Signifikanztests bei einer einfachen Stichprobe



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse



Gegeben:

- ▶ Einfache Stichprobe X_1, \dots, X_n mit
- ▶ $E(X_i) = \mu$, $\text{Var}(X_i) = \sigma^2$

Hypothesenpaare:

- a) $H_0 : \mu = \mu_0$ $H_1 : \mu \neq \mu_0$
- b) $H_0 : \mu = \mu_0$ (oder $\mu \geq \mu_0$), $H_1 : \mu < \mu_0$
- c) $H_0 : \mu = \mu_0$ (oder $\mu \leq \mu_0$), $H_1 : \mu > \mu_0$

Voraussetzungen:

- 1 Normalverteilung mit σ unbekannt (**Einstichproben-t-Test**)
oder
- 2 Beliebige Verteilung
mit $n > 30$ bzw. $5 \leq \sum x_i \leq n - 5$ (bei $B(1; p)$)
(**approximativer Gaußtest**)

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

Ablauf:

- 1 Festlegen des **Signifikanzniveaus α**
- 2 Festlegen des **Verwerfungsbereichs B**:
 - Falls $H_1 : \mu \neq \mu_0$: $B = (-\infty; -x_{1-\alpha/2}) \cup (x_{1-\alpha/2}; \infty)$
 - Falls $H_1 : \mu < \mu_0$: $B = (-\infty; -x_{1-\alpha})$
 - Falls $H_1 : \mu > \mu_0$: $B = (x_{1-\alpha}; \infty)$

Dabei steht $x_{1-\alpha/2}$ bzw. $x_{1-\alpha}$ für das jeweilige Fraktil

- der $t(n-1)$ -Verteilung bei $n \leq 29$ bzw.
 - der $N(0;1)$ -Verteilung bei $n \geq 30$.
- 3 Berechnen des **Testfunktionswertes**:

$$v = \begin{cases} \frac{\bar{x} - \mu_0}{s} \sqrt{n} & \text{falls Grundgesamtheit } N(\mu; \sigma)\text{-verteilt, } \sigma \text{ unbekannt} \\ & \text{oder falls Verteilung der GG beliebig, } n > 30, \sigma \text{ unbekannt} \\ \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n} & \text{falls Verteilung der GG beliebig, } n > 30, \sigma \text{ bekannt} \\ \frac{\bar{x} - \mu_0}{\sqrt{\mu_0(1-\mu_0)}} \sqrt{n} & \text{falls GG gemäß } B(1; \mu)\text{-verteilt, } n > 30 \end{cases}$$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
5. Datenanalyse

Beispiel t-Test: Energieaufnahme von Frauen

- ▶ Empfohlene täglich Energieaufnahme für Frauen: 7724 kJ (1845 kcal)
- ▶ Nehme einfache Stichprobe von 11 Frauen und teste zum Signifikanzniveau $\alpha = 0,05$ für
- ▶ H_0 : „Der Erwartungswert der täglichen Energieaufnahme für Frauen ist 7724 kJ“ (μ_0)
- ▶ gegen $H_1: \mu \neq \mu_0$

```
daily.intake <- c(5260, 5470, 5640, 6180, 6390, 6515, 6805, 7515, 7515, 8230, 8770)
t.test(daily.intake, alternative="two.sided", mu=7724, conf.level=0.95)
```

```
##
## One Sample t-test
##
## data:  daily.intake
## t = -2.8179, df = 10, p-value = 0.01823
## alternative hypothesis: true mean is not equal to 7724
## 95 percent confidence interval:
##  5986.348 7520.925
## sample estimates:
## mean of x
## 6753.636
```



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests
5. Datenanalyse

Beispiel:

$X_1, \dots, X_{2000} \sim B(1; p)$ mit

$$X_i = \begin{cases} 1, & \text{falls } i\text{-te Person Wähler einer bestimmten Partei} \\ 0, & \text{sonst} \end{cases}$$

Ergebnis der Stichprobe: $\sum_{i=1}^{2000} x_i = 108$

Prüfe $H_0 : p \leq 0,05$ gegen $H_1 : p > 0,05$ zum Signifikanzniveau 2 %

Lösung:

approximativer Gaußtest bei dichotomer (zweiwertiger) Verteilung; Voraussetzung 2 erfüllt: $5 \leq 108 \leq 2000 - 5$

- 1 $\alpha = 0,02$
- 2 $N(0; 1) : x_{1-\alpha} = x_{0,98} = 2,05$ (Tabelle) $\Rightarrow B = (2,05; \infty)$
- 3 $v = \frac{\frac{108}{2000} - 0,05}{\sqrt{0,05 \cdot (1-0,05)}} \sqrt{2000} = 0,82$
- 4 $v \notin B \Rightarrow H_0$ nicht verwerfen

Zusatzfrage: Entscheidung, falls $\alpha = 0,01$? \rightarrow Keine Änderung!



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
Grundlagen
Punkt-Schätzung
Intervall-Schätzung
Signifikanztests
5. Datenanalyse



- ▶ Gegeben: Einfache Stichprobe $X_1, \dots, X_n \sim N(\mu; \sigma)$
- ▶ Hypothesenpaare:

$$\begin{aligned} \text{a) } H_0 : \sigma^2 &= \sigma_0^2 & H_1 : \sigma^2 &\neq \sigma_0^2 \\ \text{b) } H_0 : \sigma^2 &= \sigma_0^2 \quad (\text{oder } \sigma^2 \geq \sigma_0^2), & H_1 : \sigma^2 &< \sigma_0^2 \\ \text{c) } H_0 : \sigma^2 &= \sigma_0^2 \quad (\text{oder } \sigma^2 \leq \sigma_0^2), & H_1 : \sigma^2 &> \sigma_0^2 \end{aligned}$$

▶ Vorgehensweise:

- 1 Festlegen des **Signifikanzniveaus** α .
- 2 Festlegen des **Verwerfungsbereichs**:

$$B = [0; x_{\alpha/2}) \cup (x_{1-\alpha/2}; \infty) \quad \text{im Fall a)}$$

$$B = [0; x_{\alpha}) \quad \text{im Fall b)}$$

$$B = (x_{1-\alpha}; \infty) \quad \text{im Fall c)}$$

- 3 Berechnung des **Testfunktionswertes**:

$$v = \frac{(n-1)s^2}{\sigma_0^2} = \frac{1}{\sigma_0^2} \sum_{i=1}^n (x_i - \bar{x})^2$$

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

Beispiel: $G \sim N(\mu; \sigma)$

$$(x_1, \dots, x_{10}) = (2100; 2130; 2150; 2170; 2210; 2070; 2230; 2150; 2230; 2200)$$

Prüfe $H_0 : \sigma = 40$, $H_1 : \sigma \neq 40$ zum Signifikanzniveau $\alpha = 0,1$

Lösung: χ^2 -Test für die Varianz, Hypothese Fall a);
Voraussetzungen sind erfüllt

① $\alpha = 0,1$

② $\chi^2(9) : x_{\frac{\alpha}{2}} = x_{0,05} = 3,33; x_{1-\frac{\alpha}{2}} = x_{0,95} = 16,92$
(Tabelle der χ^2 -Verteilung)

$$\Rightarrow B = [0; 3,33) \cup (16,92; \infty)$$

③ $\bar{x} = \frac{1}{10} (2100 + 2130 + \dots + 2200) = 2164$

$$v = \frac{1}{40^2} [(2100 - 2164)^2 + \dots + (2200 - 2164)^2] = 16,65$$

$$\Rightarrow v \notin B \Rightarrow H_0 \text{ nicht verwerfen}$$



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
 - Grundlagen
 - Punkt-Schätzung
 - Intervall-Schätzung
 - Signifikanztests
- 5. Datenanalyse



- ▶ Situation: In Grundgesamtheit G: **Zwei verbundene einfache Stichproben**, also Beobachtung **zweier Merkmale X, Y**
- ▶ Hypothese:

H_0 : Die beiden Merkmale X und Y sind in G **unabhängig**.
 H_1 : X und Y sind in G abhängig.

Vorgehensweise Kontingenztest:

- 1 Festlegen des **Signifikanzniveaus** α .
- 2 Unterteilung der x -Achse in $k \geq 2$ und die y -Achse in $l \geq 2$ disjunkte, aneinander angrenzende Intervalle A_1, \dots, A_k bzw. B_1, \dots, B_l
- 3 Erstellen einer Kontingenztabelle mit Randhäufigkeiten:

| $x \downarrow y \rightarrow$ | 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 | \ddots | \vdots | \vdots | |
| A_k | h_{k1} | h_{k2} | \dots | h_{kl} | $h_{k\bullet}$ |
| | $h_{\bullet 1}$ | $h_{\bullet 2}$ | \dots | $h_{\bullet l}$ | n |

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

Vorgehensweise Kontingenztest (Fortsetzung):

- 4 Mit dem Fraktilwert $x_{1-\alpha}$ der χ^2 -Verteilung mit $(k-1) \cdot (l-1)$ Freiheitsgraden: Berechnung des **Verwerfungsbereichs**

$$B = (x_{1-\alpha}; \infty)$$

- 5 Zu jeder Kombination aus $i = 1, \dots, k$ und $j = 1, \dots, l$: Berechnung der Größe

$$\tilde{h}_{ij} = \frac{h_{i\bullet} \cdot h_{\bullet j}}{n}$$

- 6 Berechnung des **Testfunktionswerts** v :

$$v = \sum_{i=1}^k \sum_{j=1}^l \frac{(\tilde{h}_{ij} - h_{ij})^2}{\tilde{h}_{ij}} = \sum_{i=1}^k \sum_{j=1}^l \frac{h_{ij}^2}{\tilde{h}_{ij}} - n$$

- 7 **Ablehnung** von H_0 genau dann, wenn $v \in B$.



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

Kontingenztest: Beispiel

- ▶ 400 Erstkandidaten einer praktischen Führerscheinprüfung schneiden abhängig von der besuchten Fahrschule folgendermaßen ab:

| | Fahrschule | | |
|---------------|------------|----|----|
| | A | B | C |
| bestanden | 130 | 88 | 62 |
| durchgefallen | 70 | 38 | 12 |

- ▶ Zum Signifikanzniveau von 5 % soll getestet werden, ob das Bestehen der Prüfung unabhängig von der besuchten Fahrschule ist.

Testdurchführung

- 1 Signifikanzniveau $\alpha = 5\%$
- 2 entfällt, da Skalenniveau nominal
- 3 Kontingenztafel:

| | A | B | C | Σ |
|----------|-----|-----|----|----------|
| best. | 130 | 88 | 62 | 280 |
| durchg. | 70 | 38 | 12 | 120 |
| Σ | 200 | 126 | 74 | 400 |

- 4 Berechnung der \tilde{n}_{ij} :

| | A | B | C |
|---------|-----|------|------|
| best. | 140 | 88,2 | 51,8 |
| durchg. | 60 | 37,8 | 22,2 |

- 5 χ^2 -Verteilung mit $(3-1) \cdot (2-1) = 2$ Freiheitsgraden:
 $\alpha_{1-0,05} = \alpha_{0,95} = 5,99$:

$$B = (5,99; \infty)$$

- 6
$$v = \frac{(130 - 140)^2}{140} + \dots$$

$$+ \frac{(12 - 22,2)^2}{22,2}$$

$$\approx 9,077$$

- 7 $v \in B$: Also wird H_0 abgelehnt, die Prüfungsergebnisse sind abhängig von der Fahrschule.



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

5. Datenanalyse

- 1 Statistik: Einführung
- 2 Deskriptive Statistik
- 3 Wahrscheinlichkeitstheorie
- 4 Induktive Statistik
- 5 Datenanalyse Einleitung



- 5 Datenanalyse Einleitung
 - Grundbegriffe
 - Anwendungsbereiche
 - Dreiteilung der Datenanalyse
 - Datenanalyse: Prozess



Problemstellung

- ▶ Synonym: **Multivariate Datenanalyse**, Numerische Taxonomie, Multivariatenanalyse
- ▶ Aufgaben: Analyse von **Zusammenhängen und Ähnlichkeitsbeziehungen** zwischen Elementen einer bestimmten Menge
- ▶ Teilgebiet der **Statistik**
- ▶ Einsatz sinnvoll bei großen Datenmengen mit mehr als einem Merkmal
- ▶ Ausgangspunkt: **Datenmatrix** oder **Distanzmatrix**.

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

5. Datenanalyse

Grundbegriffe

Anwendungsbereiche

Dreiteilung der Datenanalyse

Datenanalyse: Prozess



Die Datenmatrix

- ▶ enthält zeilenweise **Objekte** (Merkmalsträger, cases)
- ▶ enthält spaltenweise **Merkmale** (variables, items)

Beispiel

| | type | income | education | prestige |
|-----------------|------|--------|-----------|----------|
| engineer | prof | 72 | 86 | 88 |
| insurance.agent | wc | 55 | 71 | 41 |
| lawyer | prof | 76 | 98 | 89 |
| dentist | prof | 80 | 100 | 90 |
| mail.carrier | wc | 48 | 55 | 34 |

(Auszug aus Daten von Duncan (1961))

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse

Grundbegriffe

Anwendungsbereiche
Dreiteilung der Datenanalyse
Datenanalyse: Prozess



Die Distanzmatrix

- ▶ enthält zeilen- und spaltenweise Objekte.
- ▶ Die Einträge der Matrix sind Werte für die Verschiedenheit (**Distanzen**) zweier Objekte.

Beispiel

| | engineer | insurance.agent | lawyer | dentist | mail.carrier |
|-----------------|----------|-----------------|--------|---------|--------------|
| engineer | 0.000 | 0.676 | 0.102 | 0.149 | 0.851 |
| insurance.agent | 0.676 | 0.000 | 0.778 | 0.825 | 0.175 |
| lawyer | 0.102 | 0.778 | 0.000 | 0.047 | 0.953 |
| dentist | 0.149 | 0.825 | 0.047 | 0.000 | 1.000 |
| mail.carrier | 0.851 | 0.175 | 0.953 | 1.000 | 0.000 |

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse

Grundbegriffe

- Anwendungsbereiche
- Dreiteilung der Datenanalyse
- Datenanalyse: Prozess

3 Teilbereiche der Datenanalyse nach dem Zweck der Anwendung

Datenverdichtende Verfahren (deskriptiv)

- ▶ Kennzahlen
- ▶ Indizes
- ▶ Faktorenanalyse

Strukturaufdeckende Verfahren (explorativ)

- ▶ Kreuztabellen
- ▶ Faktorenanalyse
- ▶ Clusteranalyse
- ▶ MDS
- ▶ Korrespondenzanalyse

Strukturprüfende Verfahren (induktiv)

- ▶ Varianzanalyse
- ▶ Regressionsanalyse
- ▶ logistische Regression
- ▶ Diskriminanzanalyse
- ▶ Conjoint-Analyse



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse

Grundbegriffe

Anwendungsbereiche
Dreiteilung der Datenanalyse
Datenanalyse: Prozess



Marketing/ Marktforschung

- ▶ Marktsegmentierung
- ▶ Kundentypisierung
- ▶ Aufdecken von Marktnischen
- ▶ Ermittlung von Marktreaktionen

Sozialwissenschaften

- ▶ Einstellungsanalysen
- ▶ Qualifikationsprofile

Biologie

- ▶ Zuordnung von Pflanzen oder Tieren zu Gattungen

Medizin

- ▶ Hilfe bei Diagnosen
- ▶ Überprüfung von Therapieerfolgen

Volkswirtschaft

- ▶ Input-Output-Analysen zur Abgrenzung und Aggregation von Wirtschaftssektoren

Bibliothekswesen

- ▶ Katalogisierung
- ▶ Auffinden von ähnlichen Werken

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse

Grundbegriffe

Anwendungsbereiche

Dreiteilung der Datenanalyse

Datenanalyse: Prozess



Die klassische Dreiteilung der Datenanalyse

- ▶ **Segmentierung** (Clusteranalyse): Zusammenfassung von Objekten zu homogenen Klassen aufgrund von Ähnlichkeiten in wichtigen Merkmalsbereichen
- ▶ **Repräsentation**: Darstellung von Objekten durch Punkte im 2- oder 3-dimensionalen Raum, wobei Ähnlichkeitsbeziehungen durch räumliche Nähe zum Ausdruck kommen sollen
- ▶ **Identifikation**: Reproduktion einer gegebenen Segmentierung oder Repräsentation mit Hilfe weniger aussagekräftiger Merkmale (Ziel: Prognose, Klassifikation)

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

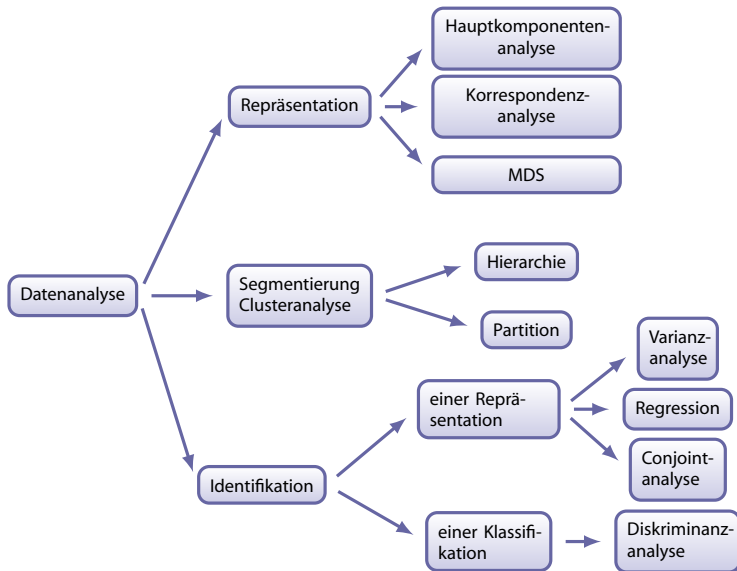
5. Datenanalyse

Grundbegriffe

Anwendungsbereiche

Dreiteilung der Datenanalyse

Datenanalyse: Prozess



1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

5. Datenanalyse

Grundbegriffe

Anwendungsbereiche

Dreiteilung der Datenanalyse

Datenanalyse: Prozess

1. Präzisierung des Untersuchungsziels

- ▶ Formulierung der **Zielsetzung**
- ▶ **Abgrenzung** der Untersuchungsobjekte
- ▶ Ableitung der taxonomischen **Aufgabenstellung**
 - Segmentierung
 - Repräsentation
 - Identifikation

2. Diskussion der Datenbasis

- ▶ **Auswahl** der Merkmale
- ▶ Festlegung des **Skalenniveaus** oder
- ▶ Charakterisierung der Objekte durch **direkte Vergleiche**

3. Datenerhebung und -erfassung

- ▶ **Primär-** oder **Sekundärerhebung**
- ▶ **Vollerhebung** oder **Teilerhebung** (Stichprobenauswahl!)
- ▶ **Datencodierung** und ggf. Dateneingabe in DV-Systeme



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
 - Grundbegriffe
 - Anwendungsbereiche
 - Dreiteilung der Datenanalyse
 - Datenanalyse: Prozess



4. Datenanalyse

- ▶ **Univariate Datenanalyse**
(Screening, erster Einblick in die Merkmalsstruktur, Plausibilitätsprüfung)
—→ **Deskriptive Verfahren**
- ▶ **Multivariate Datenanalyse**
(nicht 'statistics all', sondern Verfahrenseinsatz nach Aufgabenstellung und Zielsetzung)
—→ **Explorative und induktive Verfahren**

5. Interpretation der Ergebnisse

- ▶ Klassenstatistiken und Bezeichnungen bei **Clusteranalysen**
- ▶ Benennung der Achsen bei **Repräsentationsverfahren**
- ▶ Überprüfen der Modellqualität z.B. mittels Test- bzw. Validierungsdaten bei **Identifikationsverfahren**

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
5. Datenanalyse
 - Grundbegriffe
 - Anwendungsbereiche
 - Dreiteilung der Datenanalyse
 - Datenanalyse: Prozess