

Beschreibende Statistik

Beispiel

Treibstoffverbrauch von Neuwagen
mit Gewicht unter 1200 kg in l/100 km:

$i =$	1	2	3	4	5	6	7	8	9	10
$x_i =$	7.0	10.8	9.8	7.6	8.8	9.9	8.3	9.4	5.4	6.8
$i =$	11	12	13	14	15	16	17	18	19	20
$x_i =$	9.4	8.0	9.1	8.2	7.5	8.2	10.2	7.7	6.4	9.3
$i =$	21	22	23	24	25	26	27	28	29	30
$x_i =$	8.7	10.0	8.0	7.8	5.9	6.6	9.2	9.6	8.4	9.1
$i =$	31	32	33	34	35	36	37 = n			
$x_i =$	7.3	8.0	10.4	6.8	7.3	10.5	8.9			

Rang = 1

Rang = 5.5

Rang = 2

Stichproben-
größe

aus: Autobeilage des Tages-Anzeigers vom 6.3.89
(zitiert nach W. Stahel: Statistische Datenanalyse)

nach Größe sortieren \rightarrow geordnete Werte:

$i =$	1	2	3	4	5	6	7	8	9	10
$x_{(i)} =$	5.4	5.9	6.4	6.6	6.8	6.8	7.0	7.3	7.3	7.5
$i =$	11	12	13	14	15	16	17	18	19	20
$x_{(i)} =$	7.6	7.7	7.8	8.0	8.0	8.0	8.2	8.2	8.3	8.4
$i =$	21	22	23	24	25	26	27	28	29	30
$x_{(i)} =$	8.7	8.8	8.9	9.1	9.1	9.2	9.3	9.4	9.4	9.6
$i =$	31	32	33	34	35	36	37			
$x_{(i)} =$	9.8	9.9	10.0	10.2	10.4	10.5	10.8			

$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$ geordnete Stichprobe

Stichprobengröße

Messung der freigesetzten Wärme beim Übergang von Eis zu Wasser:

Beobachtung	1	2	3	4	5	6	7	8	9	10	11	12	13
Methode A	79.98	80.04	80.02	80.04	80.03	80.03	80.04	79.97	80.05	80.03	80.02	80.00	80.02
Methode B	80.02	79.94	79.98	79.97	79.97	80.03	79.95	79.97					

$n = 13$

Rang 1

Rang 2

Methode A der Größe nach geordnet: $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$

i	1	2	3	4	5	6	7	8	9	10	11	12	13
$x_{(i)}$	79.97	79.98	80.00	80.02	80.02	80.02	80.03	80.03	80.03	80.04	80.04	80.04	80.05

Rang 5

90% - Quantil:

$$0.9 \cdot 13 = 11.7$$

7.1. Kennzahlen

arithmetisches Mittel:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad \text{"Lagemass"}$$

empirische Varianz / Standardabweichung:

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

$$s = \sqrt{s^2} \quad \text{"Streuungsmaß"}$$

geordnete Werte



$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$$

empirisches α -Quantil ($0 < \alpha < 1$):

$x_{(k)}$ wobei $k > \alpha n$ und $k \in \mathbb{N}$ minimal


\implies approximativ $\alpha \cdot 100\%$ Daten \leq emp. α -Quantil
 $(1-\alpha) \cdot 100\%$ " $>$ " "

falls $\alpha n \in \mathbb{N}$: emp. α -Quantil = $\frac{1}{2} (x_{(\alpha n)} + x_{(\alpha n + 1)})$



»Sollen wir das arithmetische Mittel als durchschnittliche Körpergröße nehmen und den Gegner erschrecken, oder wollen wir ihn einlullen und nehmen den Median?«

$n=11$



emp. 90% Quantil: $0.9 \cdot 11 = 9.9$

$\rightarrow x_{(10)}$

emp. 50% Quantil:

empirischer Median

"Lagemass"

"mittlere Beobachtung"

unteres Quartil: emp. 25% Quantil

oberes " : " 75% "

Quartilsdifferenz = oberes Quartil - unteres Quartil

"Streuungsmaß"

Bem: emp. Median ist robustes Lagemass

7.2 Grafische Darstellungen

empirische kumulative Vert. funktion

$$\hat{F}(x) = \frac{1}{n} \# \{i; x_i \leq x\} \quad \text{Anzahl}$$
$$= \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{[x_i \leq x]}$$

$$\mathbb{1}_{[x_i \leq x]} = \begin{cases} 1 & \text{falls } x_i \leq x \\ 0 & \text{sonst} \end{cases}$$

- $\hat{F}(\cdot)$ ist eine kum. Vert. fht.
- springt an den Stellen x_i um $\frac{1}{n}$ (oder Vielfaches davon wenn mehrere gleiche Daten)

Histogramm:

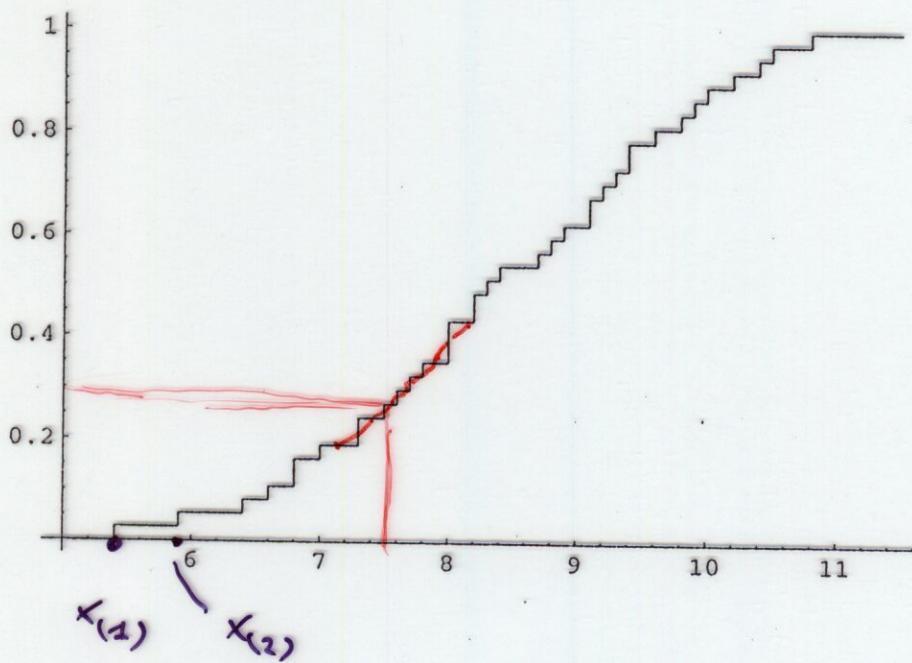
"Fläche proportional zu Häufigkeit"

Empirische kumulative Verteilungsfunktion

Die *empirische* kumulative Verteilungsfunktion ist jene Treppenfunktion, die bei $x_{(i)}$ von $(i-1)/n$ auf i/n springt ($i = 1, \dots, n$):

$$\hat{F}(x) = \frac{1}{n} \#\{i : x_{(i)} \leq x\}$$

Treibstoffverbrauch




Empirische kumulative Verteilungsfunktion

Die *empirische* kumulative Verteilungsfunktion ist jene Treppenfunktion, die bei $x_{(i)}$ von $(i-1)/n$ auf i/n springt ($i = 1, \dots, n$):

$$\hat{F}(x) = \frac{1}{n} \# \{i : x_{(i)} \leq x\}$$



Empirische kumulative Verteilungsfunktion




x

Histogramme

(Säulen- oder Balkendarstellung)





Häufigkeit
 \propto Fläche

Die Balkenhöhe ist proportional zu Häufigkeit / Klassenlänge.


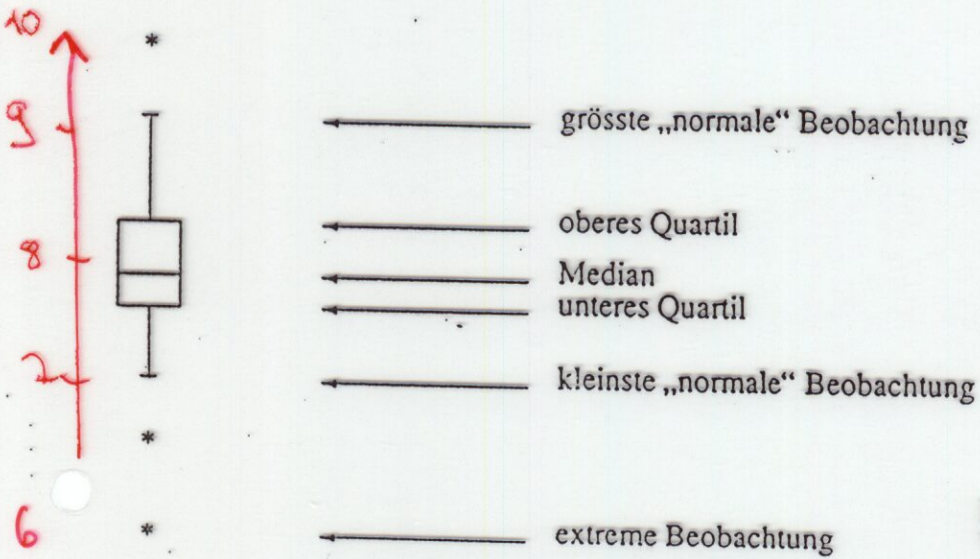


Bild 2.3.a Histogramme mit unterschiedlicher Lage (i) und mit unterschiedlicher Streuung (ii)

(Stapel)

Boxplot



höchstens
 $1.5 \cdot$ Quartilsdifferenz
 von oberem Quartil
 entfernt

Bild 2.5.d (i)
 Was der Box-Plot zeigt

(Stahel)

Quartilsdiff.





Bild 2.5.d (ii) Box-Plots zum Vergleich von Gruppen: NO_2 -Wochenmittel für die 20 Basler Stadtkreise

(Stahel)

Boxplot

- Kennzahlen für Lage und Streuung ablesbar
- Multimodalität (mehrere peaks beim Histogramm) nicht erkennlich
- geeignet um versch. Gruppen zu vergleichen