

Kap. 1. Graphische Darstellungen von Messdaten

1.1. Darstellungsformen, unterschiedliche Mittelwerte.

Empirische Untersuchungen / Befragungen:

Unterschiedliche Merkmale als Gegenstand, z.B.

- metrisch messbare Merkmale (wie Längen...)
- nominale Merkmale (Studiengang, Haarfarbe...)
- ordinale Merkmale (nominale Merkmale, die

geordnet werden können,

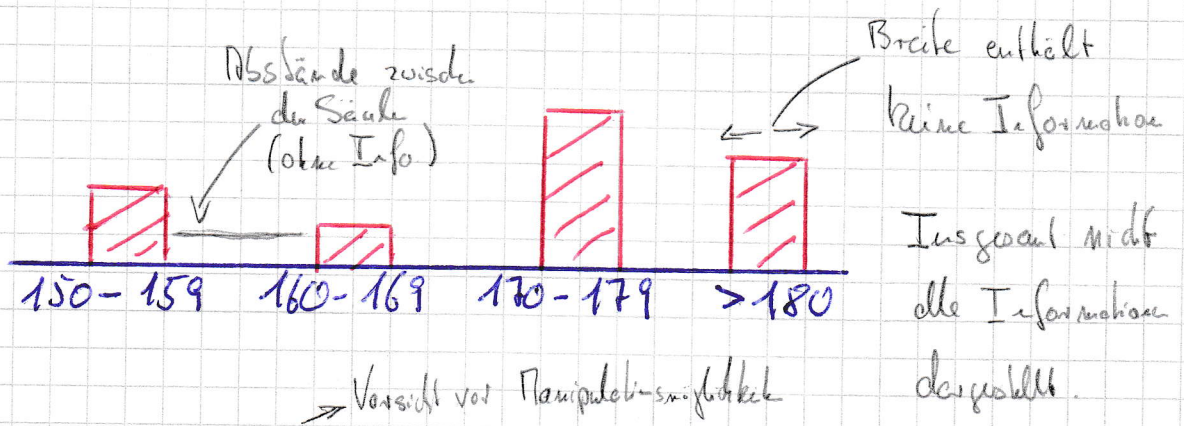
z.B. Stellen wie ... eher schlecht...
eher gut...)

Im Folgenden sind die Merkmalsausprägungen
in der Regel metrisch messbar.

Beispiel. Die Größe von 10 Personen wurde gemessen ab:

#	Person	Größe in cm
1		153
1		158
1		162
2		171
1		173
1		178
1		185
1		186
1		195

Darstellung z.B. als Säulendiagramm



Weitere Darstellungsmethoden (Histogramm, Stamm-Blatt-Darstellung etc.) in den Übungen

Darstellungen, die besonders charakteristische Kennzahlen einer Datenreihe beinhalten?

Beispiele i-) Das arithmetische Mittel (oder das Mittelwert)

N Messdaten x_i : $\bar{x} = \frac{1}{N} (x_1 + x_2 + \dots + x_{N-1} + x_N)$

→ Lagemaß: $l(x_1+a, x_2+a, \dots, x_N+a) = l(x_1, x_2, \dots, x_N) + a$, geom. Mittel $\sqrt[N]{x_1 \cdot x_2 \cdot \dots \cdot x_N}$ (kein Lagemaß)

Notation

Nach zur Abkürzung: Σ

$a_1 + a_2 + \dots + a_n = \sum_{k=1}^n a_k$.
 n — Endwert
 $k=1$ — Startwert (muss nicht 1 sein)
 — Summand
 — Laufindex

Beispiele

$\sum_{k=1}^n a_k = \sum_{l=1}^n a_l$

Legal wie man den nennt

$\sum_{k=1}^n a_k = \sum_{j=2}^{n+2} a_{j-1} = \sum_{i=-3}^{n-4} a_{i+4}$

↳ Umnennungen

$\sum_{m=0}^2 b_{2m} = b_0 + b_2 + b_4$
 $2m$ — gerade

$\sum_{m=0}^2 b_{2m+1} = b_1 + b_3 + b_5$
 $2m+1$ — ungerade

alle Summande gleich

$$\sum_{k=1}^n a = n \cdot a$$

$$\sum_{k=1}^n a_k + \sum_{k=1}^n b_k = \sum_{k=1}^n (a_k + b_k), \quad c \sum_{k=1}^n a_k = \sum_{k=1}^n (c a_k)$$

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$$

Weiter: Beispiele Kennzahlen

Vervollst:

$$\frac{1}{2} = 0,5 \hat{=} 50\%$$

z.B.) Empirische Median $x_{(1/2)}$ (auch Zentralwert genannt):

• Die Daten werden der Reihenfolge nach geordnet = Z.B.

Ist $x_1 = 185, x_2 = 179, x_3 = 171, x_4 = 195,$

$x_5 = 186, x_6 = 153, x_7 = 171, x_8 = 173, x_9 = 162, x_{10} = 158,$

so schreibt man $\leq x_2 = 179$
 $x_6 \leq x_{10} \leq x_9 \leq x_3 \leq x_7 \leq x_8 \leq x_1 \leq x_5 \leq x_4$
" " " " " " " " " "
153 158 162 171 171 173 185 186 195

• Die Daten werden umnummeriert mit der neuen

Bezeichnung, hier: (vgl. Beispiel Größe von 10 Personen)

$x_1 = 153, x_2 = 158, x_3 = 162, x_4 = 171, x_5 = 171,$

$x_6 = 173, x_7 = 179, x_8 = 185, x_9 = 186, x_{10} = 195.$

Der Zentralwert ist

$$x_{1/2} := \begin{cases} x_{(N+1)/2}, & \text{falls } N \text{ ungerade} \\ \frac{1}{2} (x_{\frac{N}{2}} + x_{(\frac{N}{2}+1)}), & \text{falls } N \text{ gerade,} \end{cases}$$

z.B. bei geordneter Reihe

$$x_1 \leq x_2 \leq x_3 \leq x_4 \leq x_5 \leq x_6 \leq x_7 \leq x_8 \leq x_9 \leq x_{10}$$

$N=10$: gerade

$$x_{1/2} = \frac{1}{2} (x_5 + x_6)$$

oder bei der geordneten Reihe

$$x_1 \leq x_2 \leq x_3 \leq x_4 \leq x_5 \leq x_6 \leq x_7 \leq x_8 \leq x_9$$

$N=9$: ungerade

$$x_{1/2} = x_5$$

Zur Lage des Medians: "Minimale & "Maximale" halten

mind. 50% \rightarrow
mind. 50% \geq

sich genau drei Weisen.

Vorbild: z.B. $p=0.65 \hat{=} 65\%$

iii.) Es sei $0 < p < 1$. Das empirische p-Quantil

wird für eine wie oben geordnete Datenreihe berechnet:

Wobei sei zunächst definiert

$$\lfloor \gamma \rfloor := \max \{ k \in \mathbb{Z} : k \leq \gamma \}$$

kleinste ganze
Zahl kleiner oder
gleich γ .

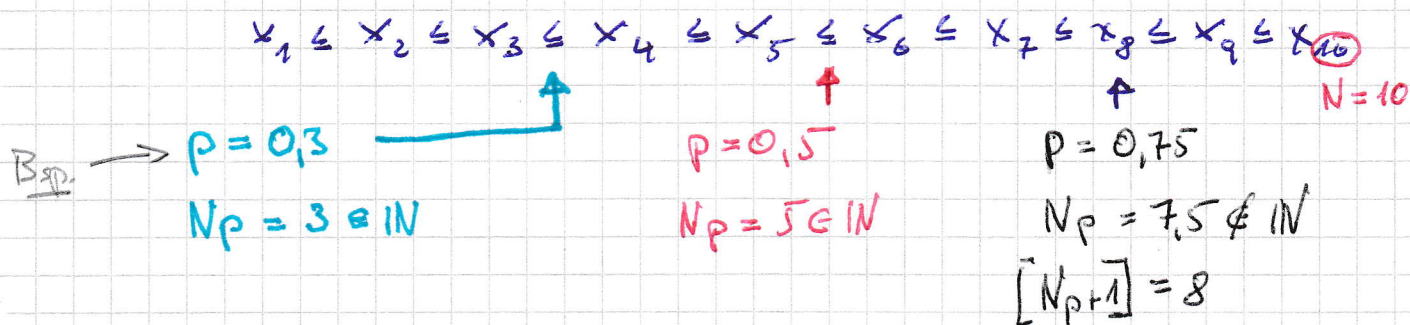
Dann ist das empirische p -Quantil:

$$x_p := \begin{cases} x_{\lfloor Np+1 \rfloor}, & \text{falls } Np \notin \mathbb{N} \\ \frac{1}{2}(x_{Np} + x_{Np+1}), & \text{falls } Np \in \mathbb{N}. \end{cases}$$

($Np \notin \mathbb{N} \Rightarrow Np+1 \notin \mathbb{N}$, $\lfloor Np+1 \rfloor$ kleinste ganze Zahl größer oder gleich Np ,

(Prosz)Übung: $p = \frac{1}{2} \rightarrow$ beide Definitionen stimmen überein)

Beispiel geordnete Reihe



Namensgebung

- $p = 0.25$ $x_{0.25}$: unteres Quantil
- $p = 0.75$ $x_{0.75}$: oberes Quantil
- $x_{0.75} - x_{0.25}$: Quantilsabstand

Im Beispiel Größe von 10 Personen ist:

$$x_{1/2} = \frac{1}{2} (171 + 173) = 172,$$

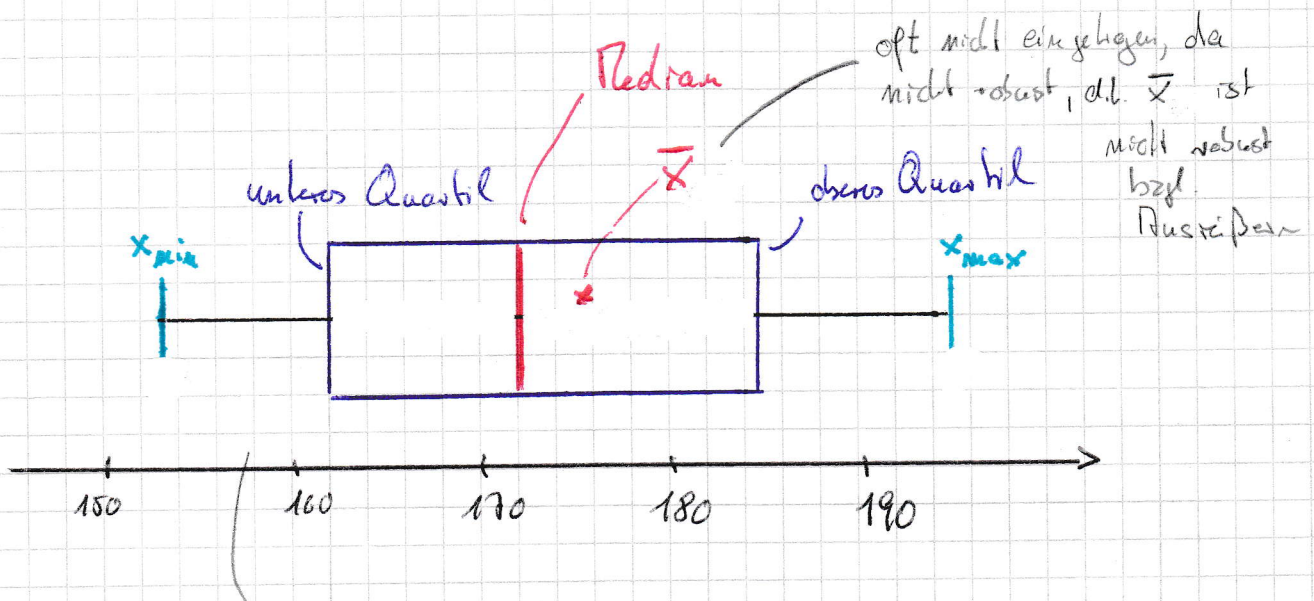
$$x_{0.25} = x_3 = 162,$$

$$x_{0.75} = x_8 = 185,$$

$$x_{0.75} - x_{0.25} = 23.$$

Weiter ist $\bar{x} = 173,3.$

Darstellung als sogenannter Boxplot:



Bemerkung: Man kann auch geeignete "Marken" an die Box definieren. Werte außerhalb dieses Bereichs sind Ausreißer.

1.2. Bemerkungen zur weiteren Analyse.

Wie kann man die Streuung von Messdaten beschreiben?

Ein mögliches Hilfsmittel: Empirische Varianz

(oder Stichprobenvarianz oder Varianz der Messreihe)

Definition 1. Man beh. eine Messreihe aus N Daten.

i.) Dann ist die Varianz S_x^2 mithilfe der quadratischen Abweichung vom Mittelwert definiert:

$$\begin{aligned} \underline{S_x^2} &:= \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_{N-1} - \bar{x})^2 + (x_N - \bar{x})^2}{N-1} \\ &= \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \end{aligned}$$

ii.) Die (empirische) Standardabweichung ist

$$\underline{S_x} := \sqrt{S_x^2}$$

Bemerkungen.

i.) Positive und negative Abweichungen vom Mittelwert werden hier in gleicher Weise berücksichtigt.

ii.) Manchmal wird der Vorfaktor $\frac{1}{N}$ statt $\frac{1}{(N-1)}$ verwendet. Die Wahl $\frac{1}{N-1}$ hat etwas mit der sogenannten "Erwartungstreue vom Schätzverfahren" zu tun.

↳ Erwartungstreue
↔ Wahrheit.

Im dem Beispiel ist $s_x^2 \approx 176,23$, $s_x \approx 13,28$.

Man rechnet wirklich leicht nach (→ Präsenzübungen)

Satz 1. (Verschiebungssatz für die Stichprobenvarianz)

Es gilt

$$s_x^2 = \frac{1}{N-1} \left[\left(\sum_{i=1}^N x_i^2 \right) - N \bar{x}^2 \right].$$

Bemerkung. Natürlich ist man an der relativen Streuung

interessiert, d.h. für $x_i > 0$ betrachtet man den

empirischen Variationskoeffizienten $v = \frac{s_x}{\bar{x}}$.

(Im Beispiel $v = 0,077 \approx 7,7\%$)

Beispiel Kolbenkurbipette: Vgl. [10].