

Formelsammlung

Deskriptive Statistik

Absolute Häufigkeit

$H(a_j) :=$ "Anzahl der Fälle, in denen a_j auftritt", $j = 1, 2, \dots, k$.

Relative Häufigkeit

$$h(a_j) := \frac{1}{n} \cdot H(a_j), \quad j = 1, 2, \dots, k.$$

Empirische Verteilungsfunktion (Nichtgruppiert)

$$F(x) := \begin{cases} 0 & \text{für } x \leq a_1 \\ \sum_{i=1}^j h(a_i) & \text{für } a_j < x \leq a_{j+1} \\ 1 & \text{für } x > a_k \end{cases}$$

Wichtige Eigenschaften der Verteilungsfunktion

1.

$$F(x) = A(X < x).$$

2.

$$0 \leq F(x) \leq 1$$

3.

$$\forall x_1, x_2 : x_1 < x_2 \Rightarrow F(x_1) \leq F(x_2)$$

4.

$$A(x_1 \leq X < x_2) = F(x_2) - F(x_1)$$

5.

$$\begin{aligned} x \rightarrow -\infty & \quad F(x) \rightarrow 0 \\ x \rightarrow +\infty & \quad F(x) \rightarrow 1. \end{aligned}$$

6.

Eine empirische Verteilungsfunktion ist mindestens linksseitig stetig und hat höchstens endlich viele Sprungstellen.

Absolute Klassenhäufigkeiten

$H_i :=$ "Anzahl der Beobachtungswerte in der Klasse K_i ", $i = 1, 2, \dots, p$.

Relative Klassenhäufigkeiten

$$h_i := \frac{H_i}{n}, \quad i = 1, 2, \dots, p.$$

Empirische Verteilungsfunktion (Gruppiert)

$$F(x) := \begin{cases} 0 & \text{für } x \leq m_1 \\ \sum_{i=1}^j h(a_i) & \text{für } m_j < x \leq m_{j+1} \\ 1 & \text{für } x > m_k \end{cases}$$

Lagemaße	Ungruppiert	Gruppiert
Arith. Mittel	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ $= \frac{1}{n} \sum_{j=1}^k a_j \cdot H_n(a_j)$	$\bar{x} \approx \frac{1}{n} \sum_{i=1}^p m_i \cdot H_i$ $m_i := \frac{g_i + G_i}{2}, \quad i = 1, 2, \dots, p$ $\frac{1}{n} \sum_{i=1}^p g_i \cdot H_i \leq \bar{x} \leq \frac{1}{n} \sum_{i=1}^p G_i \cdot H_i$
Median	$Me := \begin{cases} x_{\lfloor \frac{n+1}{2} \rfloor} & \text{für } n : \text{ ungerade} \\ \frac{1}{2} \left(x_{\lfloor \frac{n}{2} \rfloor} + x_{\lfloor \frac{n}{2} \rfloor + 1} \right) & \text{für } n : \text{ gerade} \end{cases}$	$\begin{cases} \sum_{j=1}^{i-1} h_j < 0.5 \\ \sum_{j=1}^i h_j \geq 0.5 \end{cases}$ $Me \approx g_i + \frac{0.5 - \sum_{j=1}^{i-1} h_j}{h_i} \cdot b_i$
α - Quantil	$\tilde{x}_\alpha := \begin{cases} x_{[k]} & \text{fall } n \cdot \alpha \text{ keine ganze Zahl ist.} \\ & (k \text{ ist dann die auf } n \cdot \alpha \text{ folgende ganze Zahl.}) \\ \frac{1}{2} (x_{[k]} + x_{[k+1]}) & \text{falls } n \cdot \alpha \text{ eine ganze Zahl ist.} \\ & (\text{Es ist dann } k = n \cdot \alpha.) \end{cases}$	$\begin{cases} \sum_{j=1}^{i-1} h_j < \alpha \\ \sum_{j=1}^i h_j \geq \alpha \end{cases}, \quad (0 < \alpha < 1)$ $\tilde{x}_\alpha \approx g_i + \frac{\alpha - \sum_{j=1}^{i-1} h_j}{h_i} \cdot b_i$

<i>Lagemaße</i>	<i>Ungruppiert</i>	<i>Gruppiert</i>
Modus	Als <i>Modus</i> bezeichnet man diejenige Merkmalsausprägung, die <u>eindeutig</u> am häufigsten vorkommt.	Im Falle eines gruppierten Datenmaterials wird er in der Klasse K_i mit der maximalen Häufigkeit folgendermaßen berechnet: $M := g_i + \frac{h_i - h_{i-1}}{2h_i - h_{i-1} - h_{i+1}} \cdot b_i$
Geometrisches Mittel	$\bar{x}_g := \sqrt[n]{\prod_{i=1}^n x_i} = \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n}$	

<i>Streuungsmaße</i>	<i>Ungruppiert</i>	<i>Gruppiert</i>
Spannweite	$R := x_{\max} - x_{\min}$	$R \approx G_p - g_1$
Quartilsabstand	$QA := \tilde{x}_{0.75} - \tilde{x}_{0.25}$	$QA := \tilde{x}_{0.75} - \tilde{x}_{0.25}$
Mittlerer Quartilsabstand	$\bar{Q} := \frac{1}{2} \left(\tilde{x}_{0.75} - \tilde{x}_{0.25} \right)$	$\bar{Q} := \frac{1}{2} \left(\tilde{x}_{0.75} - \tilde{x}_{0.25} \right)$
Varianz	$\sigma^2 := \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2$ (bei einer <i>Grundgesamtheit</i>) $\left(= \frac{1}{N} \sum_{i=1}^N x_i^2 - \mu^2 \right).$ $s^2 := \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ $= \frac{\sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2}{n-1}.$ (Bei einer <i>Stichprobe</i>)	$\sigma^2 \approx \frac{1}{N} \sum_{i=1}^p (\bar{x}_i - \mu)^2 \cdot H_i,$ (bei einer <i>Grundgesamtheit</i>) $s^2 \approx \frac{1}{n-1} \sum_{i=1}^p (\bar{x}_i - \bar{x})^2 \cdot H_i,$ (bei einer <i>Stichprobe</i>) Falls \bar{x}_i nicht existieren, werden sie durch m_i ersetzt.
Standardabweichung	$s > 0$ bzw. $\sigma > 0$	$s > 0$ bzw. $\sigma > 0$
Variationskoeffizient	$v := \frac{s}{\bar{x}}$ bzw. $v := \frac{\sigma}{\mu}$	$v := \frac{s}{\bar{x}}$ bzw. $v := \frac{\sigma}{\mu}$

Korrelation

Korrelationskoeffizient (Bravais - Pearson):

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \cdot \sum_{i=1}^n (y_i - \bar{y})^2}}$$

Regression:

Normalgleichungen zur Bestimmung der **einfachen linearen Regressionsfunktion**

$$y^* = a_0 + a_1 x$$

$$\begin{cases} n \cdot a_0 + a_1 \cdot \sum_{i=1}^n x_i = \sum_{i=1}^n y_i \\ a_0 \cdot \sum_{i=1}^n x_i + a_1 \cdot \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i \cdot y_i \end{cases}$$

Korrelationskoeffizient (linear)

$$r_{yx} := \frac{n \cdot \sum_{i=1}^n x_i \cdot y_i - \sum_{i=1}^n x_i \cdot \sum_{i=1}^n y_i}{\sqrt{\left(n \cdot \sum_{i=1}^n x_i^2 - \sum_{i=1}^n x_i \cdot \sum_{i=1}^n x_i \right) \cdot \left(n \cdot \sum_{i=1}^n y_i^2 - \sum_{i=1}^n y_i \cdot \sum_{i=1}^n y_i \right)}}$$

Bestimmtheitsmaß (linear)

$$B_{yx} := r_{yx}^2.$$

Bestimmtheitsmaß (allgemein)

$$r_{yx}^2 := \frac{\sum_{i=1}^n \left(y_i^* - \bar{y} \right)^2}{\sum_{i=1}^n \left(y_i - \bar{y} \right)^2}.$$