

7.3.2 Modalwert

Eine Ausprägung a eines Merkmals X ist ein *Modalwert* (oder *Modus*) der Stichprobe x_1, \dots, x_n , wenn es keine Ausprägung gibt, die in der Stichprobe häufiger vorkommt, d.h. wenn für die Häufigkeitsverteilung H_n der Stichprobe gilt:

$$H_n(a) \geq H_n(x_i) \quad \text{für alle } 1 \leq i \leq n.$$

Modalwerte sind Lagemaße, aber im Allgemeinen nicht eindeutig. Falls doch, werden sie mit x_{mod} bezeichnet und die Häufigkeitsverteilung heißt *unimodal*. Modalwerte lassen sich auch bei Stichproben von nominalen Merkmalen bestimmen.

7.3.3 Quantile

Zu x_1, \dots, x_n bezeichne $x_{(1)}, \dots, x_{(n)}$ die *geordnete Stichprobe*, d.h. es gilt

$$\{x_1, \dots, x_n\} = \{x_{(1)}, \dots, x_{(n)}\} \text{ und } x_{(1)} \leq \dots \leq x_{(n)}$$


Zur Beschreibung der Struktur einer Stichprobe zieht man dann sogenannte *Quantile* heran:

Definition

Sei $p \in [0, 1]$. Eine Ausprägung x_p heißt **p -Quantil** der Stichprobe x_1, \dots, x_n , wenn für die Häufigkeitsverteilung h_n gilt:

$$\sum_{\substack{1 \leq i \leq n \\ a_i \leq x_p}} h_n(a_i) \geq p \quad \text{und} \quad \sum_{\substack{1 \leq i \leq n \\ a_i \geq x_p}} h_n(a_i) \geq 1 - p, \quad (*)$$

d.h. mindestens $p \cdot 100\%$ der Stichprobenwerte sind $\leq x_p$ und mindestens $(1 - p) \cdot 100\%$ der Stichprobenwerte sind $\geq x_p$.



Bemerkung

- Für $p = \frac{1}{2}$ heißt das p -Quantil $x_{0,5}$ *Median* (oder *Zentralwert*),

d.h. mindestens 50 % der Stichprobenwerte sind größer gleich und mindestens 50 % sind kleiner gleich $x_{0,5}$.

- Das $\frac{1}{4}$ -Quantil $x_{0,25}$ heißt *unteres Quartil*, das $\frac{3}{4}$ -Quantil $x_{0,75}$ *oberes Quartil*.

- $x_{j-0,1}$ heißt *j-tes Dezil*.

- Im Fall $p = 0$ erhält man den kleinsten Wert, das *Minimum* $x_{min} = x_{(1)}$ der Stichprobe, im Fall $p = 1$ den größten Wert, das *Maximum* $x_{max} = x_{(n)}$.

Alle p -Quantile sind Lagemaße. Verglichen mit dem arithmetischen Mittel ist der Median robuster (d.h. weniger anfällig) gegenüber „Ausreißern“.

Satz 7.3.3 (Berechnung des p -Quantils). Sei $0 < p < 1$. Eine Ausprägung a ist genau dann ein p -Quantil der Stichprobe x_1, \dots, x_n , wenn gilt:

$$a = x_{(\lceil np \rceil)}, \text{ falls } np \notin \mathbb{N} \quad \text{bzw.} \quad x_{(np)} \leq a \leq x_{(np+1)}, \text{ falls } np \in \mathbb{N}, \quad (**).$$

Hierbei steht $\lceil x \rceil$ für die kleinste ganze Zahl größer oder gleich x .

← obere Gaussklammer

Insbesondere gilt für den Median $x_{0,5}$ somit

Bsp $\lceil 2,1 \rceil = 3, \quad \lceil 0,9 \rceil = 0$

$$x_{0,5} = \begin{cases} x_{(\frac{n+1}{2})}, & \text{falls } n \text{ ungerade,} \\ a, & \text{falls } n \text{ gerade und } a \text{ eine Ausprägung} \\ & \text{mit } x_{(\frac{n}{2})} \leq a \leq x_{(\frac{n}{2}+1)} \text{ ist.} \end{cases}$$

Einschub 7.3.4. ...

1) $i \quad 1 \quad 2 \quad 3 \quad 4 \quad 5 \quad 6 \quad 7 \quad 8 \quad 9 \quad n=9$

$x_i \quad - \quad - \quad - \quad - \quad - \quad - \quad - \quad - \quad -$

$x_{(i)} \quad 2 \quad 4 \quad 7 \quad 8 \quad 10 \quad 13 \quad 15 \quad 18 \quad 20$

$p = \frac{1}{4} \quad \lceil np \rceil = \lceil 9 \cdot \frac{1}{4} \rceil = \lceil 2,25 \rceil = 3 \quad \xRightarrow{\text{Satz}} \quad x_{(3)} = x_{1/4} = 7$

$p = \frac{3}{4} \quad \lceil np \rceil = \lceil 9 \cdot \frac{3}{4} \rceil = \lceil \frac{27}{4} \rceil = 7 \quad \xRightarrow{\text{Satz}} \quad x_{(7)} = x_{3/4} = 15$

$p = \frac{1}{2} \quad \lceil 9 \cdot \frac{1}{2} \rceil = \lceil 4,5 \rceil = 5 \quad \Rightarrow \quad x_{1/2} = x_{(5)} = 10$

2) In 1) nur bis $i = 8$, also $n = 8$

$p = \frac{1}{2} : np = 8 \cdot \frac{1}{2} = 4 \in \mathbb{N} \quad \xRightarrow{\text{Satz}} \quad x_{(np)} = x_{(4)} \leq a \leq x_{(np+1)} = x_{(5)}$

$\Rightarrow 8 \leq a \leq 10$, d.h. jede Ausprägung a , die $8 \leq a \leq 10$

erfüllt ist, ist ein $x_{1/2}$ -Quantil, also sowohl 8 als

auch 10 ist ein Median (also nicht eindeutig).

Daher gibt es folgende Konvention: wähle

$a = \frac{1}{2} (x_{(np)} + x_{(np+1)})$ hier dann $a = 9$

7.4 Streumaße

Definition 7.4.1. Sei x_1, \dots, x_n eine Stichprobe eines quantitativen Merkmals X . Eine Funktion

$$s: \mathbb{R}^n \rightarrow \mathbb{R}, \quad (x_1, \dots, x_n) \mapsto s(x_1, \dots, x_n)$$

heißt **Streumaß**, wenn für alle $a \in \mathbb{R}$ und alle $(x_1, \dots, x_n) \in \mathbb{R}^n$ gilt:

$$s(x_1 + a, \dots, x_n + a) = s(x_1, \dots, x_n),$$

d.h. durch Verschieben der Stichprobe ändert sich die Streuung nicht. Oftmals fordert man für ein Streumaß s auch noch, dass $s(0, 0, \dots, 0) = 0$ gilt.

Beispiele 7.4.2.

- **Spannweite:** $x_{\max} - x_{\min} = x_{(n)} - x_{(1)}$
- **p -Quantilsabstand, $p \in (0, \frac{1}{2})$:** $x_{1-p} - x_p$ = Differenz von $(1-p)$ - und p -Quantil; im Fall $p = \frac{1}{4}$ heißt der p -Quantilsabstand kurz **Quartilsabstand**.
- **Medianabweichung:** Median der Abstände $|x_1 - x_{0,5}|, |x_2 - x_{0,5}|, \dots, |x_n - x_{0,5}|$ der Stichprobenwerte vom Median $x_{0,5}$
- **Mittlere absolute Abweichung vom Median:** $\tilde{s} = \frac{1}{n} \sum_{i=1}^n |x_i - x_{0,5}|$
- **Mittlere quadratische Abweichung vom arithmetischen Mittel (oder Varianz):**

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

- **Standardabweichung:** $s = \sqrt{s^2}$

Es handelt sich hier in allen Fällen um **Streumaße**, da zur Berechnung **stets Differenzen von Stichprobenwerten und Lagemaßen bzw. von zwei Lagemaßen verwendet werden**. Bei Verschiebung der Stichprobe um a , heben sich die Verschiebungen somit gegenseitig auf.

Satz 7.4.3 (Berechnung der Varianz, Steinersche Formel). *Die Varianz s^2 einer Stichprobe x_1, \dots, x_n lässt sich wie folgt berechnen:*

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

Beweis

Mithilfe der Binomischen Formel gilt:

$$\begin{aligned} s^2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n (x_i^2 - 2x_i\bar{x} + \bar{x}^2) = \frac{1}{n} \sum_{i=1}^n x_i^2 - \frac{2}{n} \bar{x} \sum_{i=1}^n x_i + \frac{1}{n} \cdot n\bar{x}^2 \\ &= \frac{1}{n} \sum_{i=1}^n x_i^2 - 2\bar{x}^2 + \bar{x}^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 \end{aligned}$$

□

□

Beispiele 7.4.4. Urliste $n = 13$

$$x_1 = 2, 1, 3, 1, 3, 5, 5, 5, 5, 5, 3, 5, 5 = x_{13}$$

geordnet

$$x_{(1)} = 1, 1, 2, 3, 3, 3, 5, 5, 5, 5, 5, 5, 5 = x_{(13)}$$

Median $x_{0,5} = x_{(\lceil 13 \cdot 0,5 \rceil)} = x_{(7)} = 5$

20% Quartilabstand $x_{0,2} = x_{(\lceil 13 \cdot 0,2 \rceil)} = x_{(\lceil 2,6 \rceil)} = x_{(3)} = 2$

$x_{0,8} = x_{(\lceil 13 \cdot 0,8 \rceil)} = x_{(11)} = 5$

$x_{1p} - x_p = x_{0,8} - x_{0,2} = 5 - 2 = 3$

Medianabweichung $x_{0,5} = 5$

Abstände zum Median $|x_{(1)} - 5|, \dots, |x_{(13)} - 5|$ ergibt
4, 4, 3, 2, 2, 2, 0, 0, 0, 0, 0, 0, 0

geordnet also

0, 0, 0, 0, 0, 0, 0, 0, 2, 2, 2, 3, 4, 4

Medianabweichung (wie oben aus $\lceil 13 \cdot 0,5 \rceil$)

Mittlere absolute Abweichung vom Median $x_{0,5} = 5$

$\bar{s} = \frac{1}{13} (|x_1 - x_{0,5}| + \dots + |x_{13} - x_{0,5}|) = \frac{17}{13}$

Mittelwert $\bar{x} = \frac{1}{13} (\overbrace{1+1}^{= 1 \cdot H_{13}(1)} + \overbrace{2+3+3}^{= 3 \cdot H_{13}(3)} + \underbrace{5+5+5+5+5+5+5}_{= 5 \cdot H_{13}(5)})$ $n=13$

$= \frac{1}{13} (1 \cdot \overbrace{H_{13}(1)}^2 + 2 \cdot H_{13}(2) + 3 \cdot H_{13}(3) + 5 \cdot H_{13}(5)) = \frac{48}{13}$ $\leftarrow \text{Tim}$

Varianz (Skinner)

$s^2 = \frac{1}{13} (1^2 + 1^2 + 2^2 + 3^2 + 3^2 + 3^2 + 5^2 + \dots + 5^2) - \bar{x}^2$
 $= \frac{1}{13} (1^2 \cdot H_{13}(1) + 2^2 \cdot H_{13}(2) + 3^2 \cdot H_{13}(3) + 5^2 \cdot H_{13}(5)) - \bar{x}^2$

$$= \frac{1}{13} (2 + 4 + 27 + 7 \cdot 25) - \left(\frac{48}{13}\right)^2 = \frac{2}{13} \dots$$

Vorteil Steiner bei Berechnung:

Mittelwert x_i^2
 Mittelwert x_i

$\left. \begin{array}{l} \text{Mittelwert } x_i^2 \\ \text{Mittelwert } x_i \end{array} \right\} \begin{array}{l} \text{im} \\ \Rightarrow \\ \text{Satz} \\ 7.4.4 \end{array} \text{ alle } H_n(a_i) \text{ gleich}$