

1. EINDIMENSIONALES DATENMATERIAL (1 MERKMAL)

1.1. Notation

- n Zahl der Merkmalsträger (Beobachtungswerte oder Messwerte)
- k Zahl der Merkmalsausprägungen bzw. Klassen (Cave: Abweichende Belegung bei Lorenzkurve)
- r Zahl disjunkter statistischer Massen
- x_i i-ter Beobachtungs- oder Messwert ($i = 1; \dots; n$)
- a_j j-te Merkmalsausprägung bzw. j-te Klasse der n Beobachtungs-/Messwerte ($j = 1; \dots; k$)
- $h(a_j)$ = h_j = Absolute Häufigkeit der j-ten Merkmalsausprägung bzw. der j-ten Klasse ($j = 1; \dots; k$)
- $f(a_j)$ = f_j = Relative Häufigkeit der j-ten Merkmalsausprägung bzw. der j-ten Klasse ($j = 1; \dots; k$)
- $H(x)$ Kumulierte absolute Häufigkeit
- $F(x)$ Kumulierte relative Häufigkeit (empirische Verteilungsfunktion)

1.2. Häufigkeiten

Absolute Häufigkeit der Merkmalsausprägung j: $h(a_j)$ $j = 1; \dots; k$

Relative Häufigkeit der Merkmalsausprägung j: $f(a_j) = \frac{1}{n} \cdot h(a_j)$ $j = 1; \dots; k$

Es gilt zwangsläufig: $\sum_{j=1}^k h(a_j) = n$ und $\sum_{j=1}^k f(a_j) = 1$

Absolute kumulierte Häufigkeit: $H(x) = \sum_{a_j \leq x} h(a_j)$

Relative kumulierte Häufigkeit: $F(x) = \sum_{a_j \leq x} f(a_j) = \frac{1}{n} \cdot H(x)$

1.3. Lageparameter

Allgemein liegt das p-Quantil an der Stelle: $x_{(n-1)p+1}$ [z.B. $p = 0,25$ oder $p = 0,5$]

Median: $x_{Med} = \begin{cases} x_{\frac{n+1}{2}} & ; \text{ falls } n \text{ ungerade} \\ \frac{1}{2} \cdot (x_{\frac{n}{2}} + x_{\frac{n}{2}+1}) & ; \text{ falls } n \text{ gerade} \end{cases}$

Arithmetisches Mittel (falls Urliste gegeben): $\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \cdot \sum_{i=1}^n x_i$

Arithmetisches Mittel (falls Häufigkeitsverteilung gegeben / keine Klassierung): $\bar{x} = \frac{1}{n} \cdot \sum_{j=1}^k a_j \cdot h(a_j) = \sum_{j=1}^k a_j \cdot f(a_j)$

Arithmetisches Mittel (falls klassierte Daten): $\bar{x}^* = \frac{1}{n} \cdot \sum_{j=1}^k a_j^* \cdot h(a_j) = \sum_{j=1}^k a_j^* \cdot f(a_j)$
 $[a_j^* = \text{Klassenmitte der } j\text{-ten Klasse}]$

Gesamtmittel (= Arithmetisches Mittel einer Gesamtmasse):

$$\bar{x}_{Ges} = \frac{1}{n} \cdot \sum_{j=1}^r n_j \cdot \bar{x}_j$$

Harmonisches Mittel:

$$\bar{x}_H = \frac{\sum_{j=1}^k h(x_j)}{\sum_{j=1}^k \frac{h(x_j)}{x_j}}$$

Geometrisches Mittel:

$$\bar{x}_{Geom} = \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n}$$

Falls c_1, \dots, c_n Zuwachsraten, so gilt für die durchschnittliche Zuwachsrate \bar{c} :

$$\bar{c} = \sqrt[n]{(1+c_1) \cdot (1+c_2) \cdot \dots \cdot (1+c_n)} - 1$$

1.4. Streuungsparameter

Spannweite:

$$SP = \max_i x_i - \min_i x_i \quad i = 1; \dots; n$$

Durchschnittliche Abweichung von λ :

$$\bar{s}_\lambda = \frac{1}{n} \cdot \sum_{i=1}^n |x_i - \lambda| = \sum_{j=1}^k |a_j - \lambda| \cdot f(a_j)$$

Zumeist verwendet man $\lambda = x_{Med}$ oder $\lambda = \bar{x}$

Varianz (falls Urliste gegeben):

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

Varianz (falls Häufigkeitsverteilung gegeben):

$$s^2 = \frac{1}{n} \cdot \sum_{j=1}^k (a_j - \bar{x})^2 \cdot h(a_j) = \sum_{j=1}^k (a_j - \bar{x})^2 \cdot f(a_j)$$

Varianz (falls klassierte Daten):

$$s^2 = \frac{1}{n} \cdot \sum_{j=1}^k (a_j^* - \bar{x})^2 \cdot h(a_j) = \sum_{j=1}^k (a_j^* - \bar{x})^2 \cdot f(a_j)$$

$$[a_j^* = \text{Klassenmitte der } j\text{-ten Klasse}]$$

Varianzzerlegungssatz:

$$s_{Ges}^2 = \underbrace{\frac{1}{n} \cdot \sum_{i=1}^k n_i \cdot s_i^2}_{\text{interne Varianz}} + \underbrace{\frac{1}{n} \cdot \sum_{i=1}^k n_i \cdot (\bar{x}_i - \bar{x}_{Ges})^2}_{\text{externe Varianz}}$$

Standardabweichung:

$$s = \sqrt{s^2}$$

Variationskoeffizient:

$$V = \frac{s}{\bar{x}}$$

1.5. KonzentrationsmessungLorenzkurve: Nicht-Klassierte Daten

Anteil an der gesamten
Merkmalssumme, den die k „kleinsten“
Merkmalsträger auf sich vereinigen:

$$V_k = \frac{\sum_{i=1}^k X_i}{\sum_{i=1}^n X_i}$$

Anteil der k „kleinsten“ Merkmalsträger
an der Gesamtzahl der Merkmalsträger:

$$U_k = \frac{k}{n}$$

Lorenzkurve: Klassierte Daten [Cave: Gesamtzahl der Klassen = l]

Anteil an der gesamten
Merkmalssumme, den die k „kleinsten“
Klassen auf sich vereinigen:

$$V_k = \frac{\sum_{j=1}^k h(a_j) \cdot \text{Klassenmitte}_j}{\sum_{j=1}^l h(a_j) \cdot \text{Klassenmitte}_j}$$

Anteil der Merkmalsträger in den k
„kleinsten“ Klassen an der Gesamtzahl
der Merkmalsträger:

$$U_k = \frac{\sum_{j=1}^k h(a_j)}{n}$$

Gini-Koeffizient

Ansatz:

$$G = \frac{\text{Konzentrationsfläche}}{0,5}$$

Berechnung:

$$G = \frac{2 \cdot \sum_{i=1}^n i \cdot x_i - (n+1) \cdot \sum_{i=1}^n x_i}{n \cdot \sum_{i=1}^n x_i} = \frac{2 \cdot \sum_{i=1}^n i \cdot p_i - (n+1)}{n}$$

$$\text{mit: } p_i = \frac{x_i}{\sum_{i=1}^n x_i} \quad [= \text{relative Merkmalswerte}]$$

Normierter Gini-Koeffizient:

$$G^* = \frac{n}{n-1} \cdot G \quad \text{mit } G^* \in [0;1]$$

Weitere Konzentrationsmaße

Konzentrationsindex (Anteil der
Merkmalssumme, den die g größten
Merkmalsträger auf sich vereinen):

$$CR_g = 1 - L\left(\frac{n-g}{n}\right) \quad [\text{absolute Werte gegeben}]$$

$$CR_g = 100 - L\left(100 \cdot \frac{n-g}{n}\right) [\text{Prozentwerte gegeben}]$$

Herfindahl-Index:
$$H = \sum_{i=1}^n p_i^2 \quad \text{mit: } H \in \left[\frac{1}{n}; 1\right]$$

2. ZWEIDIMENSIONALES DATENMATERIAL (2 MERKMALE)

2.1. Notation

n Zahl der Merkmalsträger (Beobachtungswerte oder Messwerte)
k Zahl der Merkmalsausprägungen bzw. Klassen der Variable X
l Zahl der Merkmalsausprägungen bzw. Klassen der Variable Y
 a_i i-te Merkmalsausprägung bzw. i-te Klasse des Merkmals X ($i = 1; \dots; k$)
 b_j j-te Merkmalsausprägung bzw. j-te Klasse des Merkmals Y ($j = 1; \dots; l$)

2.2. Häufigkeiten

Gemeinsame Häufigkeiten:
$$h_{ij} = h(a_i; b_j)$$

Randhäufigkeiten des ersten Merkmals:
$$h_{i\bullet} = \sum_{j=1}^l h_{ij}$$

Randhäufigkeiten des zweiten Merkmals:
$$h_{\bullet j} = \sum_{i=1}^k h_{ij}$$

Bedingte relative Häufigkeit der Ausprägung a_i unter der Voraussetzung, dass b_j vorliegt:
$$f_1(a_i | b_j) = \frac{h_{ij}}{h_{\bullet j}}$$

Bedingte relative Häufigkeit der Ausprägung b_j unter der Voraussetzung, dass a_i vorliegt:
$$f_2(b_j | a_i) = \frac{h_{ij}}{h_{i\bullet}}$$

Falls X und Y unabhängig, so gilt:
$$f_1(a_i | b_j) = \frac{h_{ij}}{h_{\bullet j}} = \frac{h_{i\bullet}}{n} = \text{relative Häufigkeit von } a_i$$

$$f_2(b_j | a_i) = \frac{h_{ij}}{h_{i\bullet}} = \frac{h_{\bullet j}}{n} = \text{relative Häufigkeit von } b_j$$

sowie:
$$h_{ij} = \frac{h_{i\bullet} \cdot h_{\bullet j}}{n}$$

2.3. Kovarianz

Kovarianz für n Merkmalswerte:

$$\begin{aligned} \text{COV}(X;Y) &= \frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y}) \\ &= \frac{1}{n} \cdot \left(\sum_{i=1}^n x_i \cdot y_i \right) - \bar{x} \cdot \bar{y} \end{aligned}$$

2.4. Korrelationskoeffizienten

(Bravais-Pearson-) Korrelationskoeffizient:

$$r_{BP} = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \cdot \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{\text{COV}(X;Y)}{s_x \cdot s_y}$$

Es gilt stets: $-1 \leq r_{BP} \leq 1$

Rangkorrelationskoeffizient von Spearman:

$$r_{Sp} = 1 - \frac{6 \cdot \sum_{i=1}^n (R_i - R'_i)^2}{(n-1) \cdot n \cdot (n+1)}$$

wobei R_i = Rangnummern der x_i – Werte R'_i = Rangnummern der y_i – WerteEs gilt stets: $-1 \leq r_{Sp} \leq 1$.

(Korrigierter) Kontingenzkoeffizient:

$$K_{Korr} = \frac{K}{K_{\max}} = \frac{\sqrt{\frac{X^2}{n+X^2}}}{\sqrt{\frac{M-1}{M}}}$$

$$\text{Mit: } M = \min[k;l] \quad X^2 = \sum_{i=1}^k \sum_{j=1}^l \frac{(h_{ij} - \tilde{h}_{ij})^2}{\tilde{h}_{ij}}$$

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

2.5. Lineare Regression

Regressionsgerade:

$$y = \hat{a} + \hat{b} \cdot x$$

...mit den Parametern:

$$\hat{a} = \bar{y} - \hat{b} \cdot \bar{x}$$

$$\hat{b} = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\text{COV}(X;Y)}{s_x^2}$$

3. INDEXZAHLEN**3.1. Notation**

$p_0(1), \dots, p_0(n)$	Preise der Güter 1, ..., n in der Basisperiode 0
$p_t(1), \dots, p_t(n)$	Preise der Güter 1, ..., n in der Berichtsperiode t
$q_0(1), \dots, q_0(n)$	Mengen der Güter 1, ..., n in der Basisperiode 0
$q_t(1), \dots, q_t(n)$	Mengen der Güter 1, ..., n in der Berichtsperiode t

3.2. Indices

LASPEYRES-Preisindex:

$$P_{0t}^L = \frac{\sum_{i=1}^n p_t(i) \cdot q_0(i)}{\sum_{i=1}^n p_0(i) \cdot q_0(i)}$$

PAASCHE-Preisindex:

$$P_{0t}^P = \frac{\sum_{i=1}^n p_t(i) \cdot q_t(i)}{\sum_{i=1}^n p_0(i) \cdot q_t(i)}$$

LASPEYRES-Mengenindex:

$$Q_{0t}^L = \frac{\sum_{i=1}^n p_0(i) \cdot q_t(i)}{\sum_{i=1}^n p_0(i) \cdot q_0(i)}$$

PAASCHE-Mengenindex:

$$Q_{0t}^P = \frac{\sum_{i=1}^n p_t(i) \cdot q_t(i)}{\sum_{i=1}^n p_t(i) \cdot q_0(i)}$$