

Musterlösung zur Übungsklausur Statistik

TI 23 / Oettinger / 3.2025

Aufgabe 1

- (a) Richtig: das arithmetische Mittel reagiert im Gegensatz zum Median empfindlich auf Ausreißer.
- (b) Falsch: die Varianz und damit auch die Standardabweichung kann natürlich auch Null werden (wenn alle Abweichungen vom arithmetischen Mittel zu Null verschwinden) - dann ist eigentlich keine Statistik nötig.
- (c) Richtig: es handelt sich um eine Summe quadrierter Größen.
- (d) Falsch: der Modus ist die am häufigsten auftretende Merkmalsausprägung in einer Stichprobe.
- (e) Falsch: es handelt sich um ein mittleres Wachstum, es kann auch negativ sein.

Aufgabe 2

Daten zur Gewichtsverteilung mit Häufigkeitsdichte:

| i | Klasse $(x_i^u; x_i^o]$ | h_i | Mitte | Breite | Dichte h_i^* | rel. Häufigkeit f_i | kumuliert F_i |
|-----|-------------------------|-------|--------|--------|----------------|-----------------------|-----------------|
| 1 | (985; 995] | 15 | 990 | 10 | 1,5 | 0,3 | 0,3 |
| 2 | (995; 1000] | 5 | 997,5 | 5 | 1 | 0,1 | 0,4 |
| 3 | (1000; 1005] | 20 | 1002,5 | 5 | 4 | 0,4 | 0,8 |
| 4 | (1005; 1020] | 10 | 1012,5 | 15 | 0,666 | 0,2 | 1 |

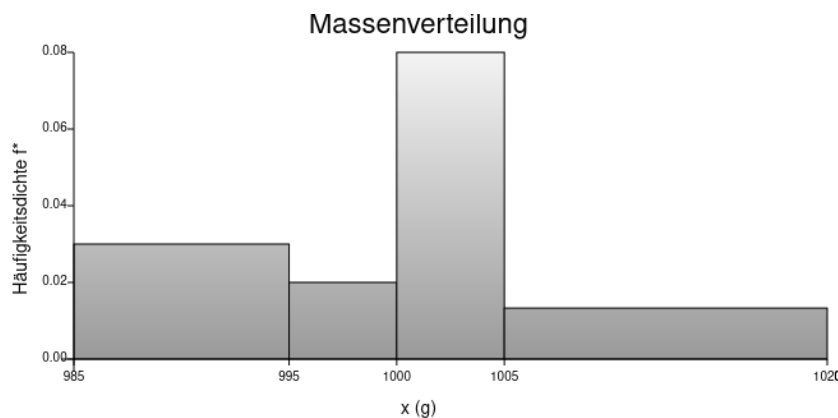


Abbildung 1: Histogramm zum Gewicht des Quallengelees

Die Näherung für das arithmetische Mittel (in Gramm) über die Klassenmitten ist

$$\bar{x} \approx \frac{1}{50} (15 \cdot 990 + 5 \cdot 997,5 + 20 \cdot 1002,5 + 10 \cdot 1012,5) = 1000,25.$$

Die Hälfte der untersuchten Pakete (25) wird in der dritten Klasse erreicht ($i = 3$), der Median kann ebenfalls geschätzt werden (in Gramm)

$$\bar{x}_Z \approx x_3^u + (x_3^o - x_3^u) \frac{0,5 - F(x_3^u)}{F(x_3^o) - F(x_3^u)} = 1000 + 5 \cdot \frac{0,5 - 0,4}{0,8 - 0,4} = 1001,25$$

Als typischer Wert sind beide geeignet - in den meisten Fällen gibt der Median die Verhältnisse der Verteilung aber etwas besser wieder.

Aufgabe 3

Die arithmetischen Mittel für die Siedetemperatur T_S und den Druck sind $\bar{x} = 95,6^\circ\text{C}$ und $\bar{y} = 652,806 \text{ mm Hg}$. Damit lassen sich die benötigten Daten berechnen:

| T_S (°C) | Druck | $x_i - \bar{x}$ | $y_i - \bar{y}$ | $(x_i - \bar{x})^2$ | $(y_i - \bar{y})^2$ | $(x_i - \bar{x})(y_i - \bar{y})$ |
|------------|--------|-----------------|-----------------|---------------------|---------------------|----------------------------------|
| 90.3 | 528.07 | -5.3 | -124.736 | 28.09 | 15559.069696 | 661.1008 |
| 92.2 | 568.96 | -3.4 | -83.846 | 11.56 | 7030.151716 | 285.0764 |
| 93 | 588.01 | -2.6 | -64.796 | 6.76 | 4198.521616 | 168.4696 |
| 93.8 | 606.81 | -1.8 | -45.996 | 3.24 | 2115.632016 | 82.7928 |
| 94.1 | 610.11 | -1.5 | -42.696 | 2.25 | 1822.948416 | 64.044 |
| 95.9 | 674.88 | 0.3 | 22.074 | 0.09 | 487.261476 | 6.6222 |
| 98.6 | 723.65 | 3 | 70.844 | 9 | 5018.872336 | 212.532 |
| 98.1 | 705.1 | 2.5 | 52.294 | 6.25 | 2734.662436 | 130.735 |
| 99.9 | 758.95 | 4.3 | 106.144 | 18.49 | 11266.548736 | 456.4192 |
| 100.1 | 763.52 | 4.5 | 110.714 | 20.25 | 12257.589796 | 498.213 |

Die Kovarianz (nicht gefragt, in °C · mm Hg) ist

$$s_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = 256,60$$


Lineare Regression: sei $y(x) = a \cdot x + b$:

$$a = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} = 24,21 \text{ mm Hg / } ^\circ\text{C}$$

und

$$b = \bar{y} - a\bar{x} = -1661,88 \text{ mm Hg.}$$

Die Standardabweichungen der beiden Größen sind $s_x = 3,26^\circ\text{C}$ und $s_y = 79,05 \text{ mm Hg}$. Plot der Daten:



Aufgabe 4

Die benötigten Daten zur Aufgabe:

| Zahl der Tabellen x_i | Tage früher | Tage jetzt | kumuliert früher | kumuliert jetzt |
|-------------------------|-------------|------------|------------------|-----------------|
| 1 | 60 | 5 | 60 | 5 |
| 2 | 160 | 10 | 220 | 15 |
| 3 | 110 | 25 | 330 | 40 |
| 4 | 0 | 20 | 330 | 60 |
| 5 | 60 | 0 | 390 | 60 |
| 6 | 50 | 0 | 440 | 60 |
| 8 | 0 | 40 | 440 | 100 |

a) Die Aussage ist: Lohnt sich der Droide (ist die Produktivität angestiegen?).

b) Benötigt werden das Arithmetische Mittel und der Median:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^m h_i x_i$$

$$\bar{x} = \frac{1}{440} (60 + 2 \cdot 160 + 3 \cdot 110 + 4 \cdot 0 + 5 \cdot 60 + 6 \cdot 50 + 8 \cdot 0) = 2,977 \text{ ohne Droide,}$$

$$\bar{x} = \frac{1}{100} (5 + 2 \cdot 10 + 3 \cdot 25 + 4 \cdot 20 + 5 \cdot 0 + 6 \cdot 0 + 8 \cdot 40) = 5 \text{ mit Droide.}$$

Der Median lässt sich aus den Daten in der Tabelle ablesen, für die Daten ohne den Droiden

$$\bar{x}_Z = \frac{x_{220} + x_{221}}{2} = 2,5,$$

nach der Einführung des Droiden

$$\bar{x}_Z = \frac{x_{50} + x_{51}}{2} = 4.$$

Die mittlere absolute Abweichung vom arithmetischen Mittel ist

$$\begin{aligned} d_{\bar{x}} &= \frac{1}{n} \sum_{i=1}^m h_i |x_i - \bar{x}|, \\ &= 1,25 \text{ ohne Droide bzw.} \\ &= 2,4 \text{ mit Droide.} \end{aligned}$$

Die mittlere absolute Abweichung vom Median ist

$$\begin{aligned} d_{\bar{x}_Z} &= \frac{1}{n} \sum_{i=1}^m h_i |x_i - \bar{x}_Z|, \\ &= 1,25 \text{ ohne Droide bzw.} \\ &= 2,2 \text{ mit Droide.} \end{aligned}$$

Aufgabe 4

Redezeit von Politikern, alle Angaben und Ergebnisse in Minuten:

| Politiker | A | B | C | D | E | F |
|-----------|---|---|----|----|----|----|
| Redezeit | 6 | 8 | 10 | 12 | 20 | 10 |

(a) Geordneter Vektor der Merkmalswerte: (6, 8, 10, 10, 12, 20). Median ist

$$\bar{x}_Z = \frac{10 + 10}{2} = 10.$$

(b) $\bar{x} = \frac{1}{6} \cdot (6 + 8 + 10 + 10 + 12 + 20) = 11.$

(c) $s_w = \max(x_i) - \min(x_i) = 20 - 6 = 14.$

(d) mittlere absolute Abweichung

$$d_{\bar{x}} = \frac{1}{6} \sum_{i=1}^n |x_i - \bar{x}|$$

$$= \frac{1}{6} (|6 - 11| + |8 - 11| + 2 \cdot |10 - 11| + |12 - 11| + |20 - 11|) = 10/3$$

Aufgabe 5

a) Die benötigten Daten:

| Einkommen in Talern | Klassenbreite in Tausend Talern | Häufigkeit | relativ | kumuliert | Dichte |
|------------------------|------------------------------------|------------|---------|-----------|--------|
|]0-500] | 0,5 | 9 | 0,09 | 0,09 | 18 |
|]500-1000] | 0,5 | 13 | 0,13 | 0,22 | 26 |
|]1000-1500] | 0,5 | 32 | 0,32 | 0,54 | 64 |
|]1500-2000] | 0,5 | 41 | 0,41 | 0,95 | 82 |
|]2000-3000] | 1,0 | 3 | 0,03 | 0,98 | 3 |
|]3000-5000] | 2,0 | 2 | 0,02 | 1,0 | 1 |

Histogramm der Einkommen:




Abbildung 2: Einkommensverteilung in Entenhausen

b) arithmetisches Mittel (in Tausend Taler):

$$\bar{x} = \frac{1}{100}(0,25 \cdot 9 + 0,75 \cdot 13 + 1,25 \cdot 32 + 2,5 \cdot 3 + 4,0 \cdot 2) = \frac{139,25}{100} = 1,39$$

50% der befragten Personen werden in der 3.Klasse erreicht, der Median (in Tausend Taler) ist

$$F(\bar{x}_Z) = x_3^u + (x_3^o - x_3^u) \frac{F(\bar{x}_Z) - F(x_3^u)}{F(x_3^o) - F(x_3^u)} = x_3^u + (x_3^o - x_3^u) \frac{F(0,5) - F(x_3^u)}{F(x_3^o) - F(x_3^u)}$$

$$1 + (1,5 - 1) \cdot \frac{0,5 - 0,22}{0,54 - 0,22} = 1,44.$$

Der Median ist etwas größer - die Verteilung scheint leicht rechtssteil.

c) Für die Lorenzkurve wird das gesamte Einkommen benötigt (in Tausend Talern):

$$q_{ges} = 0,25 \cdot 9 + 0,75 \cdot 13 + 1,25 \cdot 32 + 2,5 \cdot 3 + 4,0 \cdot 2 = 139,25$$

Jetzt kann der Anteil der Personen in jeder Klasse am Gesamteinkommen berechnet werden:

$$q_k = h_k \cdot (x_k^o + x_k^u) / 2 \cdot \frac{1}{q_{ges}}$$

| Einkommen in Talern | relative Häufigkeit f_k | kumuliert F_k | Anteil q_k | kumuliert Q_k |
|------------------------|------------------------------|--------------------|-----------------|--------------------|
|]0-500] | 0,09 | 0,09 | 0,016 | 0,016 |
|]500-1000] | 0,13 | 0,22 | 0,070 | 0,102 |
|]1000-1500] | 0,32 | 0,54 | 0,287 | 0,389 |
|]1500-2000] | 0,41 | 0,95 | 0,515 | 0,904 |
|]2000-3000] | 0,03 | 0,98 | 0,054 | 0,958 |
|]3000-5000] | 0,02 | 1,0 | 0,057 | 1 |

Lorenz-Plot:




Abbildung 3: Lorenzkurve der Einkommensverteilung in Entenhausen

Der Gini-Koeffizient entspricht der doppelten Fläche zwischen den beiden Kurven. Man erkennt, dass die relative Konzentration (und damit der Gini-Koeffizient) nicht besonders groß ist.

Aufgabe 6

Landtagswahlen: die Aussage des Herrn Trumpeimer kann durch Vergleich der Variationskoeffizienten überprüft werden. Benötigt werden die arithmetischen Mittel (in %)

$$\bar{x}_A = \frac{1}{7} (5,6 + 6,3 + 6,6 + 6,9 + 7,1 + 7,6 + 6,1) = 6,6$$

$$\bar{x}_B = \frac{1}{7} (40,4 + 41,9 + 47,9 + 40,4 + 48,9 + 41,4 + 42,9) = 43,4$$

sowie die Varianzen und die daraus berechneten Standardabweichungen

$$s_A^2 = \frac{1}{7} (5,6^2 + 6,3^2 + 6,6^2 + 6,9^2 + 7,1^2 + 7,6^2 + 6,1^2) - 6,6^2$$

$$= 0,383$$

$$\Rightarrow s_A = \sqrt{s_A^2} = 0,619$$

$$\begin{aligned}
s_B^2 &= \frac{1}{7} (40,4^2 + 41,9^2 + 47,9^2 + 40,4^2 + 48,9^2 + 41,4^2 + 42,9^2) - 43,4^2 \\
&= 10,714 \\
\Rightarrow s_B &= \sqrt{s_B^2} = 3,273.
\end{aligned}$$

Die Variationskoeffizienten $v_x = \frac{s_x}{\bar{x}}$ für die beiden Stichproben sind

$$v_A = \frac{s_A}{\bar{x}_A} = \frac{0,619}{6,6} = 0,094$$

und

$$v_B = \frac{s_B}{\bar{x}_B} = \frac{3,273}{43,4} = 0,075.$$

Damit wird klar, dass Herr Trumpheimer falsch liegt, die Verteilung der Stimmenanteile für seine Partei A ist deutlich breiter.