

Lagemaße als Lösung eines Optimierungsproblems

Gegeben sei die Urliste x_1, \dots, x_n eines intervallskalierten Merkmals X , die zu einer Zahl a^* zusammengefasst werden soll. Man könnte sagen, der beste Wert a^* ist derjenige, der den Gesamtabstand zwischen a^* und den Daten minimiert.

Misst man den Abstand

quadratisch	$(x - a^*)^2$	so ergibt sich	$a^* = \bar{x}$
linear durch den Absolutbetrag	$ x - a^* $	so ergibt sich	$a^* = x_{med}$

Für alle anderen Werte $a \in \mathbb{R}$ gilt:

$$\sum_{i=1}^n (x_i - \bar{x})^2 \leq \sum_{i=1}^n (x_i - a)^2,$$

$$\sum_{i=1}^n |x_i - x_{med}| \leq \sum_{i=1}^n |x_i - a|.$$

3.1.5 Geometrisches Mittel

Sei $T := \{0, \dots, n\}$ eine Menge von Zeitpunkten und $B(i) =: b_i$ ein zum Zeitpunkt i erhobenes Merkmal, z.B. das Bruttosozialprodukt.

Für $i = 1, \dots, n$ heißt

$$x_i = \frac{b_i}{b_{i-1}}$$

der i -te *Wachstumsfaktor* und

$$r_i = \frac{b_i - b_{i-1}}{b_{i-1}} = x_i - 1$$

die i -te *Wachstumsrate*.

Man nennt

$$\bar{x}_{geom} := \left(\prod_{i=1}^n x_i \right)^{\frac{1}{n}} = (x_1 \cdot x_2 \cdot \dots \cdot x_n)^{\frac{1}{n}}$$

das **geometrische Mittel der Wachstumsfaktoren** x_1, \dots, x_n .

Beispiel : Wirtschaftswachstum gemessen zu drei Zeitpunkten.

i	0	1	2
b_i	1000	1500	750
x_i		1.5	0.5
r_i		0.5	-0.5

Geometrisches Mittel der Wachstumsfaktoren:

$$\bar{x}_{geom} = \left(\prod_{i=1}^n x_i \right)^{\frac{1}{n}} = (x_1 \cdot x_2)^{\frac{1}{2}} = \sqrt{1.5 \cdot 0.5} = \sqrt{0.75} \approx 0.8660$$

Bemerkungen:

- Es gilt

$$b_n = b_0 \cdot (\bar{x}_{geom})^n$$

d.h. \bar{x}_{geom} ist tatsächlich ein durchschnittlicher Wachstumsfaktor, nämlich derjenige Wert, der sich aus b_n und b_0 ergäbe, wenn zu allen Zeitpunkten konstantes Wachstum geherrscht hätte.

- Das geometrische Mittel kann auch zur Prognose (unter der Stabilitätsannahme, dass das durchschnittliches Wachstum gleich bleibt) verwendet werden:

$$b_{n+q} = b_n \cdot (\bar{x}_{geom})^q, \quad q \in \mathbb{N}.$$

- Logarithmieren liefert:

$$\ln \bar{x}_{geom} = \frac{1}{n} \sum_{i=1}^n \ln x_i.$$

Das geometrische Mittel ist also ein arithmetisches Mittel auf der logarithmierten Skala.

- Man kann zeigen:

$$\bar{x}_{geom} \leq \bar{x}$$

i.A. würde also die Angabe von \bar{x} zu hohe Wachstumsraten vortäuschen.

3.1.6 Harmonisches Mittel

Beispiel: Die Entfernung von A nach B sei 99 km. Herr K. humpelt von A nach B mit konstant 1 km/h und fährt zurück mit konstant 99 km/h. Wie groß ist seine Durchschnittsgeschwindigkeit?

Die naive Lösung: 50 km/h ist **falsch!**

$$\text{Durchschnittsgeschwindigkeit} = \frac{\text{zurückgelegter Weg}}{\text{Zeit}} = \frac{198 \text{ km}}{100 \text{ h}} = 1.98 \text{ km/h}$$

Allgemein: Sei x_1, \dots, x_n mit $x_i \neq 0$ für alle i die Urliste eines verhältnisskalierten Merkmals X . Dann heißt

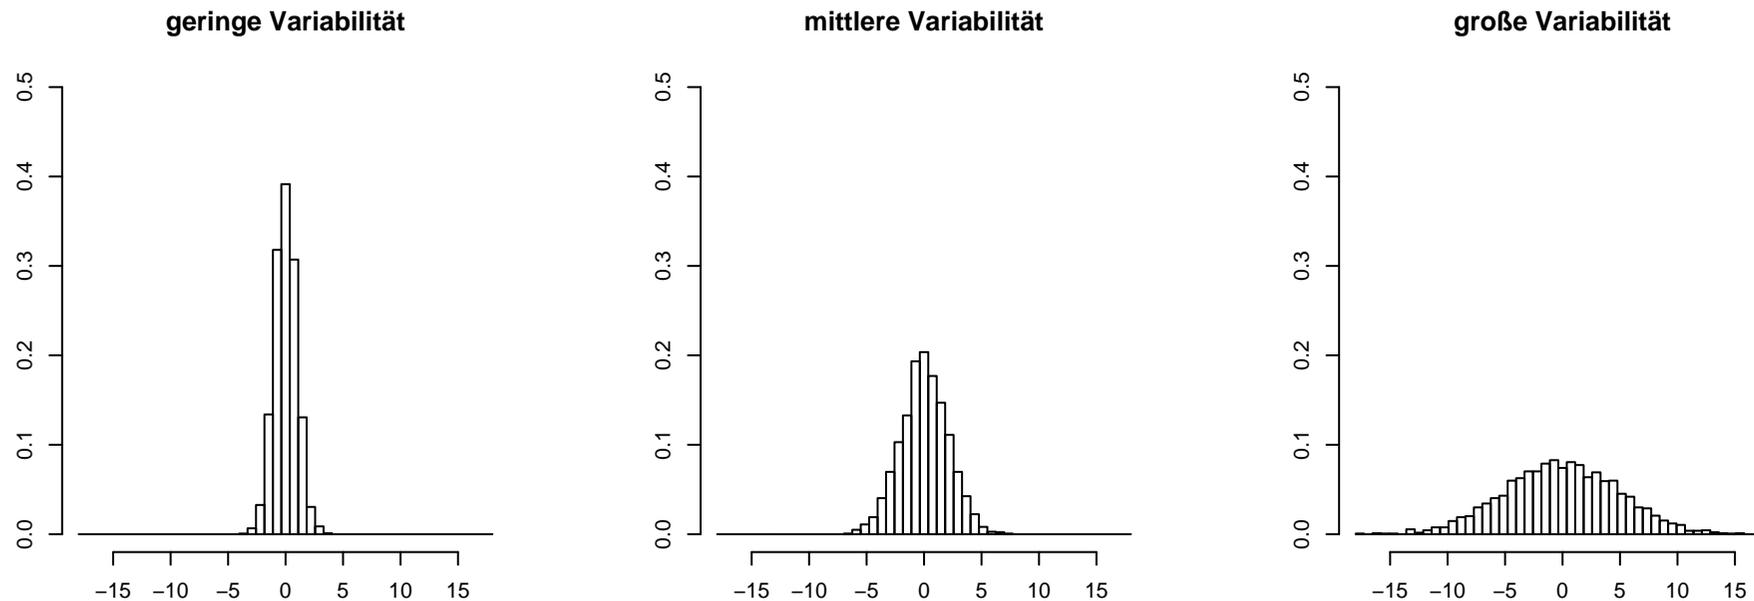
$$\bar{x}_{har} := \frac{1}{\frac{1}{n} \sum_{i=1}^n \frac{1}{x_i}}$$

das **harmonische Mittel** der Werte x_1, \dots, x_n .

3.2 Streuungsmaße

Eine Verteilung ist durch die Angabe von einem oder mehreren Lagemaßen nur unzureichend beschrieben.

Beispiel: Häufigkeitsverteilungen mit gleicher zentraler Tendenz:



Streuungsmaße beantworten Fragen wie

- Wie groß ist die durchschnittliche Abweichung vom Mittelwert?
- Über welchen Bereich erstrecken sich die Beobachtungen?
- Wie stark schwanken die Beobachtungen?

Bemerkung:

Von Streuung im eigentlichen Sinne kann man nur bei mindestens intervallskalierten Daten sprechen, da nur dort Abstände interpretierbar sind.

3.2.1 Varianz und Standardabweichung

Sei x_1, \dots, x_n die Urliste eines intervallskalierten Merkmals X . Dann heißt

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

die (empirische) Varianz oder Stichprobenvarianz und

$$\tilde{s}_X := \sqrt{\tilde{s}_X^2}$$

die empirische Streuung, Stichprobenstreuung oder Standardabweichung von X .

Bemerkungen:

- Die Varianz misst die durchschnittliche quadrierte Abweichung vom Mittelwert.
- Vorsicht: Der Begriff Streuung wird in einem doppelten Sinne gebraucht: Allgemein als Phänomen generell („wir suchen nach Maßzahlen zur Beschreibung der Streuung der Daten“), andererseits als eine bestimmte Maßzahl für das Problem.
- Durch das Quadrieren tragen negative und positive Abweichungen vom Mittelwert gleichermaßen zur Varianz bei.
- Die Varianz besitzt im Vergleich zum Merkmal X die quadrierte Einheit. Sie ist daher unanschaulicher zu interpretieren, besitzt aber andererseits viele mathematische Vorzüge.
- Die Standardabweichung wird in der gleichen Einheit gemessen wie X .

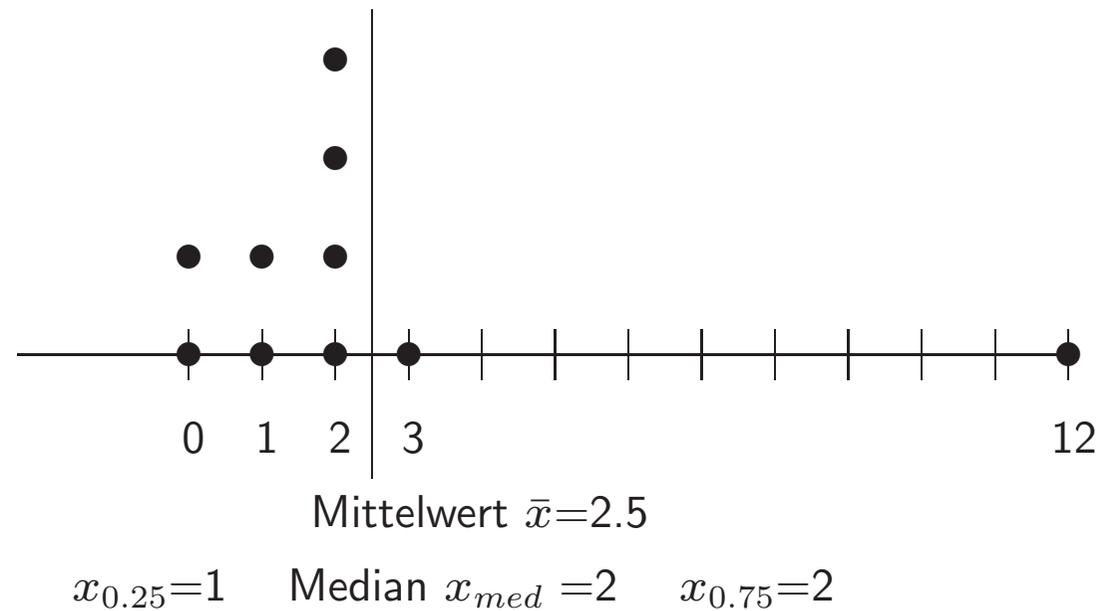
- Sind die Ausprägungen a_1, \dots, a_k mit (relativer) Häufigkeitsverteilung h_1, \dots, h_k bzw. f_1, \dots, f_k gegeben, so gilt

$$\begin{aligned}\tilde{s}_X^2 &= \frac{1}{n} \sum_{j=1}^k h_j (a_j - \bar{x})^2 = \\ &= \sum_{j=1}^k f_j (a_j - \bar{x})^2.\end{aligned}$$

- Ist aus dem Kontext klar ersichtlich welches Merkmal betrachtet wird, so lässt man das X in der Notation auch häufig weg, schreibt also einfach \tilde{s}^2 und \tilde{s} .

Beispiel: Statistikbücher.

	Häufigkeiten
$a_1 = 0$	$h_1 = 2$
$a_2 = 1$	$h_2 = 2$
$a_3 = 2$	$h_3 = 4$
$a_4 = 3$	$h_4 = 1$
$a_5 = 12$	$h_5 = 1$



Berechnung der Varianz über die ursprüngliche Formel:

$$\begin{aligned}\tilde{s}^2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \\ &= \frac{1}{10} ((0 - 2.5)^2 + (0 - 2.5)^2 + (1 - 2.5)^2 + (1 - 2.5)^2 \\ &\quad + (2 - 2.5)^2 + (2 - 2.5)^2 + (2 - 2.5)^2 + (2 - 2.5)^2 + (3 - 2.5)^2 + (12 - 2.5)^2) \\ &= \frac{108.5}{10} = 10.85\end{aligned}$$

Berechnung über die Häufigkeitsverteilung:

j	a_j	h_j	$(a_j - \bar{x})$	$(a_j - \bar{x})^2$	$(a_j - \bar{x})^2 h_j$
1	0	2	0-2.5=-2.5	6.25	12.5
2	1	2	-1.5	2.25	4.5
3	2	4	-0.5	0.25	1
4	3	1	0.5	0.25	0.25
5	12	1	9.5	90.25	90.25
Summe		10			$n\tilde{s}^2 = 108.5$

$$\implies \tilde{s}^2 = 10.85$$

Standardabweichung:

$$\tilde{s} = \sqrt{10.85} \approx 3.29 \quad (\text{Einheit: Bücher})$$

Transformationen: Wie ändert sich die Varianz bei linear affiner Transformation eines Merkmals?

Satz 3.7.

Sei x_1, \dots, x_n die Urliste eines mindestens intervallskalierten Merkmals X mit $\tilde{s}_X > 0$ und y_1, \dots, y_n die zugehörige Urliste des Merkmals $Y = a \cdot X + b$.

Dann gilt

$$\tilde{s}_Y^2 = a^2 \cdot \tilde{s}_X^2$$

und

$$\tilde{s}_Y = |a| \cdot \tilde{s}_X.$$

Bemerkungen:

- Die additive Konstante b spielt keine Rolle. Diese bewirkt lediglich eine Verschiebung der Werte, ändert aber nicht die Form und damit das Streuverhalten.
- Vorfaktoren sind bei der Varianz *quadratisch* „herauszuziehen“.
- Eine spezielle Transformation, die sogenannte *Standardisierung*, ist der Übergang zum Merkmal Z mit

$$z_i := \frac{x_i - \bar{x}}{\tilde{s}_X}.$$

Z besitzt arithmetisches Mittel 0 und (empirische) Varianz 1.

Verschiebungssatz: Es gilt

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

Achtung (sehr häufige Fehlerquelle):

Der Verschiebungssatz ist sehr bequem zum Berechnen der Varianz. Allerdings können bei sehr großen Ausprägungen beim Verwenden von Taschenrechnern starke Rundungsfehler auftreten, die das Ergebnis eventuell verfälschen.

Beispiel: Statistikbücher.

Berechne die empirische Varianz mit Hilfe des Verschiebungssatzes.

Person i	Anzahl Bücher: X x_i	x_i^2
1	0	0
2	2	4
3	1	
4	2	
5	2	
6	3	
7	0	
8	12	
9	1	
10	2	
Summe	25	
Mittelwert		

$$\tilde{s}_X^2 = \overline{x^2} - (\bar{x})^2 = 17.1 - (2.5)^2 = 10.85, \quad \tilde{s}_X = 3.29$$

Varianzzerlegung / Streuungszerlegung: Varianz bei geschichteten Daten.

Zur Erinnerung: Daten liegen oft in Schichten vor.

Beispiel: Daten über Einkommensverteilung geschichtet nach Bundesland.

Bei der Berechnung von \bar{x} waren die einzelnen Besetzungszahlen sehr wichtig.

Schicht	$1, \dots, l, \dots, z$	
Besetzungszahlen	$n_1, \dots, n_l, \dots, n_z;$	$\sum_{l=1}^z n_l = n$
Mittelwerte	$\bar{x}_1, \dots, \bar{x}_l, \dots, \bar{x}_z$	
Varianzen	$\tilde{s}_1^2, \dots, \tilde{s}_l^2, \dots, \tilde{s}_z^2$	

Für das arithmetische Mittel gilt

$$\bar{x} = \frac{1}{n} \sum_{l=1}^z n_l \bar{x}_l.$$

Seien nun

$$\tilde{s}_{innerhalb}^2 := \frac{1}{n} \sum_{l=1}^z n_l \tilde{s}_l^2$$

sowie

$$\tilde{s}_{zwischen}^2 := \frac{1}{n} \sum_{l=1}^z n_l (\bar{x}_l - \bar{x})^2$$

- $\tilde{s}_{innerhalb}^2$: durchschnittliche Varianz *innerhalb* der Schichten
- $\tilde{s}_{zwischen}^2$: Varianz der Durchschnittswerte *zwischen* den Schichten

Wann ist

- $\tilde{s}_{zwischen}^2 = 0$?
- $\tilde{s}_{innerhalb}^2 = 0$?

Wie setzt sich die Gesamtvarianz aus den beiden Bestandteilen zusammen?

Varianzzerlegung

Es gilt

$$\begin{aligned} \text{Gesamtvarianz} &= \text{Varianz in. d. Schichten} + \text{Varianz zw. d. Schichten} \\ \tilde{s}^2 &= \tilde{s}_{\text{innerhalb}}^2 + \tilde{s}_{\text{zwischen}}^2 \end{aligned}$$

Bemerkungen:

- Im Detail gilt also mit den Urlisten $\{x_{1l}, x_{2l}, \dots, x_{n_l l}\}$ in Schicht $l, l = 1, \dots, z,$

$$\frac{1}{n} \sum_{l=1}^z \left(\sum_{i=1}^{n_l} (x_{il} - \bar{x})^2 \right) = \frac{1}{n} \sum_{l=1}^z \sum_{i=1}^{n_l} (x_{il} - \bar{x}_l)^2 + \frac{1}{n} \sum_{l=1}^z n_l (\bar{x}_l - \bar{x})^2.$$

- Diese Zerlegungsmöglichkeit gilt *nur für Varianzen*, nicht aber für andere Streuungsmaße. Letztendlich ist sie der Grund für die Beliebtheit der Varianz – trotz anderer Unannehmlichkeiten. Deshalb sollte man eher von der Varianzzerlegung als von der Streuungszerlegung sprechen.
- Bei vielen Verfahren werden Varianzzerlegungen betrachtet; dies ist ein ganz grundlegendes Prinzip in der Statistik.

Interpretation der Varianzzerlegung

Beispiel: Einkommen der einzelnen Bundesländer:

Die Wichtigkeit (Erklärungskraft) der schichtbildenden Variable kann bewertet werden: je größer $\tilde{s}_{zwischen}^2$ im Vergleich zu \tilde{s}^2 bzw. $\tilde{s}_{innerhalb}^2$ ist, desto „mehr Variation“ wird durch die Schichtungsvariable erklärt.

Was bedeutet: $\tilde{s}_{zwischen}^2$ groß im Vergleich zu $\tilde{s}_{innerhalb}^2$?

Korrigierte empirische Varianz:

Neben der empirischen Varianz existiert noch eine alternative Definition der Varianz, die korrigierte empirische Varianz.

Sei x_1, \dots, x_n die Urliste eines intervallskalierten Merkmals X . Dann heißt

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

die *korrigierte empirische Varianz* oder *korrigierte Stichprobenvarianz* von X .

Bemerkungen:

- Der Sinn des Vorfaktors $\frac{1}{n-1}$ wird erst in Statistik II deutlich: s_X^2 hat theoretisch schönere Eigenschaften als \tilde{s}_X^2 .
- Für großen Stichprobenumfang n nähern sich s_X^2 und \tilde{s}_X^2 an, weil dann $n - 1 \approx n$.
- Auch für die korrigierte Varianz gilt die Aussage zu linearen Transformationen, d.h. ist x_1, \dots, x_n die Urliste eines mindestens intervallskalierten Merkmals X mit $s_X > 0$ und y_1, \dots, y_n die zugehörige Urliste des Merkmals $Y = a \cdot X + b$. Dann gilt

$$s_Y^2 = a^2 \cdot s_X^2.$$

3.2.2 Weitere Streuungsmaße

Variationskoeffizient:

Definition 3.8.

Ist $\bar{x} > 0$, so heißt die Größe

$$v_X := \frac{\tilde{s}_X}{\bar{x}}$$

Variationskoeffizient des Merkmals X .

Bemerkungen:

- Gemessen wird hier die Streuung relativ zum Mittelwert. Insbesondere ist v_X dimensionslos.
- Der Variationskoeffizient erlaubt beispielsweise auch den Vergleich der Streuung von Preisen, die in verschiedenen Währungen gemessen wurden.

Inter-Quartils-Abstand:

Sind $x_{0.25}$ und $x_{0.75}$ das obere und das untere Quartil eines Merkmals, so heißt

$$d_{QX} := x_{0.75} - x_{0.25}$$

der *Interquartilsabstand*.

Median-Absolute-Deviation:

Der Median der Werte $|x_i - x_{med}|$, $i = 1, \dots, n$ heißt Median-Absolute-Deviation von X (MAD_X).

Spannweite:

Die Größe

$$R_X := x_{(n)} - x_{(1)}$$

heißt *Spannweite* von X .

Bemerkungen

- Alle betrachteten Streuungsmaße sind nur für (mindestens) intervallskalierte Merkmale sinnvoll definiert, da sie auf Abständen (typischerweise dem Abstand der Beobachtungen zu einem Lagemaß) beruhen.
- \tilde{s}^2 , \tilde{s} , s^2 , s sind die gebräuchlichsten Streuungsmaße.
- \tilde{s}^2 , \tilde{s} , s^2 , s sind sehr empfindlich gegenüber Ausreißern! Das Gleiche gilt für die Spannweite R . MAD und d_Q hingegen entstammen der sogenannten robusten Statistik, die sich um ausreißerresistente Methoden bemüht.
- Gilt $x_1 = x_2 = \dots = x_n$, so weisen alle Streuungsmaße den Wert 0 auf. Mit Ausnahme von d_Q und MAD gilt auch die Umkehrung: Sind die Streuungsmaße (außer eben d_Q und MAD) = 0, so sind alle Werte der Urliste gleich.
- Eine häufige Ursache für Verwirrung und Missverständnisse liegt darin, dass der Begriff „Streuung“ in der Statistik in einem doppelten Sinn gebraucht wird:
 - in einem allgemeinen Sinn: Streuung als Phänomen („Die Daten streuen stark“).
 - in einem speziellen Sinn: als *eine* Maßzahl für dieses Phänomen.

Beispiel: Statistikbücher

Ausprägungen	h_j
0	2
1	2
2	4
3	1
12	1
Σ	10

$$v_X = \tilde{s}_X / \bar{x} = 3.29 / 2.5 = 1.316 \text{ (dimensionslos, normiert)}$$

$$x_{0.25} = 1 \quad x_{0.75} = 2 \quad \Rightarrow \quad d_{QX} = 1$$

$$R_X = 12$$

3.3 Box-Plot

Ziele:

- einfache Darstellung von Verteilungen und ihren Kennzahlen
- Identifikation von potentiellen Ausreißern
⇒ nicht ausreißeranfällige Meßzahlen verwenden.

Idee:

- i) markiere den Median
- ii) symbolisiere Lage der „mittleren Werte“ durch eine Box
- iii) wie weit reichen „weitere nicht atypische“ Werte
- iv) identifiziere potentielle Ausreißer: atypische (ungewöhnlich große, ungewöhnlich kleine) Werte, die genauerer Untersuchung bedürfen

zu ii) wähle mittlere 50%: Box hat Länge $dQ = x_{0.75} - x_{0.25}$

zu iii) als „nicht atypisch“ gelten alle Werte, die nicht weiter als $1.5dQ$ von der Box entfernt sind

Also bestimme:

- $x_{0.25}$, $x_{0.50}$, $x_{0.75}$.
- Interquartilsabstand: $d_{QX} = x_{0.75} - x_{0.25}$
- Zäune z_u, z_o , die am kleinsten bzw. größten Datenpunkt im Bereich $x_{0.25} - 1.5 \cdot d_{QX}$; $x_{0.75} + 1.5 \cdot d_{QX}$ liegen.
- Ausserhalb der Zäune werden *alle* Punkte eingezeichnet; sie sind ausreißerverdächtig.

Bemerkungen:

- Der Box-Plot gibt einen kompakten Überblick über die Form der Verteilung (Zentrale Tendenz, Variabilität, Schiefe, extreme Werte).
- Vorsicht bei der Anwendung von Software! Vor allem außerhalb der Box sind auch andere Darstellungen üblich (z.B. Zäune immer bis $x_{(1)}$ und $x_{(n)}$). Manchmal z.B. Unterscheidung zwischen
 - Ausreißern ($1.5 \cdot d_{QX}$ bis $3 \cdot d_{QX}$ von Rändern der Box entfernt) und
 - Extremwerten (mehr als $3 \cdot d_{QX}$ vom Rand entfernt).Oft wird der Median durch einen dicken Punkt ausgedrückt.

Box-Plots können auch zum graphischen Vergleich von Verteilungen verwendet werden:

