



Fakultät für Humanwissenschaften  
Sozialwissenschaftliche Methodenlehre  
Prof. Dr. Daniel Lois

## **Deskriptive Statistik**

Stand: April 2015 (V2)

# Inhaltsverzeichnis

1. Notation	2
2. Messniveau	3
3. Häufigkeitsverteilungen	10
4. Zentrale Tendenz	21
5. Streuung	36
6. Höhere Momente (Streuung, Kurtosis)	51
7. Übersichten	55
8. Ausgewählte Literatur	57

# Notation

- $n$  = Anzahl der Untersuchungseinheiten
- $X$  = eine Variable
- $i$  = eine einzelne, aber keine bestimmte Untersuchungseinheit
- $x_i$  = der Wert der Variable  $X$  für Untersuchungseinheit  $i$

The diagram shows the summation formula  $\sum_{i=1}^n x_i = x_1 + x_2 + \dots + x_n$  with four arrows pointing to its parts: 'Endwert' points to the upper limit  $n$ , 'Summand(en)' points to the variable  $x_i$ , 'Laufparameter' points to the lower limit  $i=1$ , and 'Startwert' points to the lower limit  $i=1$ .

$$\sum_{i=1}^n x_i = x_1 + x_2 + \dots + x_n$$

# Messniveau

- Das Messniveau einer Variablen ist von zentraler Bedeutung dafür, welche statistischen Auswertungsverfahren für diese Variable sinnvoll bzw. zulässig sind
- Die Messgenauigkeit bzw. der Informationsgehalt der Daten steigt mit dem Messniveau an
- Die folgende Folie zeigt die Messung des Merkmals „Zufriedenheit“ mit ansteigendem Messniveau
- Wir unterscheiden im Folgenden hauptsächlich zwischen kategorialen Variablen (Nominalskala, Ordinalskala) und metrischen Variablen (Intervallskala, Verhältnisskala)

# Messniveau

## Beispiel: Drei Möglichkeiten der Erfassung von Zufriedenheit

### Nominal:

0 = unzufrieden

1 = zufrieden

### Ordinal:

1 = sehr unzufrieden

2 = unzufrieden

3 = zufrieden

4 = sehr zufrieden

### Metrisch:

0 = sehr unzufrieden bis

10 = sehr zufrieden

# Messniveau

- Bei einer **Nominalskala** handelt es sich um einen Satz rangmäßig nicht geordneter Kategorien (Beispiele: Geschlecht, Religionszugehörigkeit, Beruf, Familienstand)
- Es sind nur Aussagen über Gleichheit oder Verschiedenheit eines Merkmals möglich (Mann ungleich Frau, SPD-Wähler ungleich CDU-Wähler)
- Die Kategorien sind vollständig (d.h. schließen alle Fälle ein) und disjunkt (überschneidungsfrei)
- Nominale Variablen können beliebig viele Ausprägungen haben, bei zwei Ausprägungen spricht man dichotomen (zweistufigen) Variablen

# Messniveau

- Die **Ordinalskala** hat eine zusätzliche Eigenschaft: Die Ausprägungen der Variablen lassen sich sinnvoll in eine Ordnungsrelation bringen (z.B. Schulnoten, subjektive Schichteinstufung)
- Beispiel: Oberschicht > obere Mittelschicht > Mittelschicht > Arbeiterschicht
- Ordinales Messen informiert jedoch nicht über die Größe der Differenzen zwischen den Ausprägungen einer Variablen
- Zum Beispiel ist nicht bekannt, ob der Abstand zwischen „Oberschicht“ und „oberer Mittelschicht“ größer oder kleiner ist als der Abstand zwischen „oberer Mittelschicht“ und „Mittelschicht“

# Messniveau

- Bei der **Intervallskala** müssen zusätzlich die Abstände zwischen den einzelnen Ausprägungen einer Variablen gleich sein (Äquidistanz der Intervalle)
- Zum Beispiel beträgt die Differenz zwischen zwei Lebensjahren genau 12 Monate oder die Differenz zwischen zwei Tagen genau 24 Stunden – unabhängig davon, um welches Lebensjahr oder um welche Tage es sich handelt
- Existiert zusätzlich ein absoluter (invarianter) Nullpunkt (z.B. bei Variablen wie Alter oder Einkommen), spricht man von einer **Verhältnisskala**

# Messniveau

	<b>Messniveau</b>	<b>(Zusätzliche) Eigenschaften</b>	<b>Aussagen möglich über</b>	<b>Beispiele</b>
Kategoriale Variablen	Nominalskala	Vollständige und disjunkte Kategorien	Gleichheit / Verschiedenheit	Geschlecht, Nationalität
	Ordinalskala	Ordnungsrelation	Größer / Kleiner	Schulnoten
Metrische Variablen	Intervallskala	Abstände definiert	Gleichheit von Differenzen	Geburtsjahr
	Verhältnisskala	Nullpunkt definiert	Gleichheit von Verhältnissen	Alter, Einkommen

# Häufigkeitsverteilungen

- Im Folgenden wird dargestellt, wie kategoriale oder metrische Variablen tabellarisch bzw. grafisch dargestellt werden können
- Im Falle von nominal und ordinal skalierten Variablen besteht die Aufgabe darin, absolute und relative Häufigkeiten für die einzelnen Merkmalsausprägungen darzustellen, bei metrischen Variablen werden Häufigkeitsdichten betrachtet
- Diese Arbeitsschritte stehen im Rahmen einer explorativen Datenanalyse oft am Beginn der Datenauswertung

# Häufigkeitsverteilung

In den Daten vorhandene Ausprägungen

Absolute Häufigkeit


Relative Häufigkeit

Kumulierte relative Häufigkeit

**BEFR.: TYP DER WOHNUNG**

		Häufigkeit	Prozent	Gültige Prozent	Kumulative Prozente
Gültig	ZUR UNTERMIETE	61	2,2	2,2	2,2
	DIENST-, WERKSWOHNUNG	28	1,0	1,0	3,2
	SOZ.WOHNUNGB. MIETWOH	208	7,4	7,4	10,5
	SONST.MIETWOHNUNG	838	29,7	29,7	40,3
	GEMIETETES HAUS	114	4,0	4,0	44,3
	EIGENTUMSWOHNUNG	165	5,9	5,9	50,2
	EIGENHEIM	1380	48,9	49,0	99,2
	ANDERE WOHNFORM	23	,8	,8	100,0
	Gesamtsumme	2817	99,9	100,0	
Fehlend	KEINE ANGABE	3	,1		
	Gesamtsumme	2820	100,0		

# Häufigkeitsverteilung



# Häufigkeitsverteilung


Klar strukturierte, übersichtliche Tabellen erstellen (Regel: Tinte sparen):

Tabelle: Häufigkeitsverteilung von Konfessionen in West- und Ostdeutschland



	Westdeutschland		Ostdeutschland	
	Häufigkeit	Prozent	Häufigkeit	Prozent
Katholisch	759	39.5	58	6.6
Evangelisch ohne Freikirchen	744	38.7	251	28.4
Evangelische Freikirchen	28	1.5	7	0.8
Andere christliche Religion	38	2.0	9	1.0
Nicht-christliche Religion	62	3.2	3	0.3
Keine Religionsgemeinschaft	291	15.1	555	62.9
Insgesamt	1922	100.0	883	100.0

Quelle: ALLBUS 2002


# Häufigkeitsverteilung



# Häufigkeitsverteilung



Negativbeispiele (Chart-Junk):  
Bitte kein 3D, mit Designelementen sparsam umgehen, Kreisdiagramme grundsätzlich vermeiden



# Häufigkeitsverteilung

- Um die Verteilung metrisch skalierten Merkmale mit sehr vielen Merkmalsausprägungen zu beschreiben, sind Häufigkeitstabellen oder Balkendiagramme wenig geeignet:

ALTER: BEFRAGTE<R>

		Häufigkeit	Prozent	Gültige Prozent	Kumulative Prozente
Gültig	18	32	,9	,9	,9
	19	62	1,8	1,8	2,7
	20	60	1,7	1,7	4,5
	21	42	1,2	1,2	5,7
	22	41	1,2	1,2	6,9
	23	52	1,5	1,5	8,4
	24	45	1,3	1,3	9,7
	25	37	1,1	1,1	10,7
	26	44	1,3	1,3	12,0
	27	43	1,2	1,2	13,2

usw.

Problem: zu viele Werte

# Häufigkeitsverteilung

- Lösung: Daten gruppieren (hier werden 10-Jahres-Altersklassen gebildet):


**ALTER: BEFRAGTE<R>, KATEGORISIERT**

		Häufigkeit	Prozent	Gültige Prozent	Kumulative Prozente
Gültig	18-29 JAHRE	489	17,3	17,4	17,4
	30-44 JAHRE	889	31,5	31,6	49,0
	45-59 JAHRE	691	24,5	24,6	73,6
	60-74 JAHRE	584	20,7	20,8	94,3
	75-89 JAHRE	153	5,4	5,4	99,8
	UEBER 89 JAHRE	7	,2	,2	100,0
	Gesamtsumme	2813	99,8	100,0	
Fehlend	KEINE ANGABE	7	,2		
Gesamtsumme		2820	100,0		

# Häufigkeitsverteilung


- Eine grafische Lösung ist das **Histogramm** mit folgenden Eigenschaften
  - Histogramm = Form der graphischen Darstellung der Häufigkeitsverteilung eines metrischen Merkmals, dessen Merkmalswerte in Klassen zusammengefasst wurden
  - Klassenhäufigkeiten werden durch die Flächeninhalte aneinander angrenzender Rechtecke repräsentiert
  - Die nächsten Folien zeigen sog. normierte Histogramme. Hier ist die Rechteckhöhe gleich der relativen Häufigkeitsdichte („density“), die als Quotient aus relativer Klassenhäufigkeit und Klassenbreite definiert ist
  - Die Flächeninhalte der aneinander angrenzenden Rechtecke addieren sich bei einem normierten Histogramm stets zu 1

# Häufigkeitsverteilung



Histogramm,  
Klassenbreite 2

# Häufigkeitsverteilung



Histogramm,  
Klassenbreite 5


# Zentrale Tendenz

- Insbesondere bei metrischen Merkmalen werden tabellarische Darstellungen schnell unübersichtlich
- Neben einer grafischen Betrachtung (Histogramm, Box-Plot) verwenden wir daher zusätzlich statistische Kennziffern, um zentrale Eigenschaften von Verteilungen zu beschreiben
- Zunächst werden drei Maßzahlen der zentralen Tendenz vorgestellt: Modus, Median und arithmetischer Mittelwert

# Zentrale Tendenz

- Maße der zentralen Tendenz (auch: Lagemaße) werden insofern „repräsentative“ Werte genannt, weil sie den typischen, zentralen oder durchschnittlichen Wert einer Verteilung beschreiben
- Welche Kennziffer jeweils verwendet wird, richtet sich nach dem Messniveau der Daten
- Eine einfache Maßzahl der zentralen Tendenz, die bei jedem Messniveau berechnet werden kann, ist der **Modus** (abgekürzt mit  $h$ )
- Er ist definiert als der am häufigsten vorkommende Wert einer Verteilung


# Zentrale Tendenz



Modus (h) = 4

# Zentrale Tendenz

- Eigenschaften des Modus
  - Ist eindeutig, falls die Häufigkeitsverteilung ein eindeutiges Maximum besitzt
  - Kann bereits ab Nominalskalenniveau berechnet werden
  - Ist problematisch bei bi- und multimodalen Verteilungen (siehe Grafik rechts); allgemein bei sehr vielen, ähnlich besetzten Kategorien



# Zentrale Tendenz

- Der **Median** ( $\tilde{x}$ ) kennzeichnet die exakte Mitte einer Verteilung, deren Ausprägungen (aufsteigend) geordnet sind, d.h.:

$$\tilde{x} = \begin{cases} x_{\left(\frac{n+1}{2}\right)} & \text{für } n \text{ ungerade} \\ \frac{1}{2} \left( x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n}{2}+1\right)} \right) & \text{für } n \text{ gerade} \end{cases}$$

# Zentrale Tendenz

- Beispiel 1 (ungerade,  $n = 11$ ): 3, 4, 4, 5, 6, **7**, 8, 8, 8, 9, 10
- Hier ist der Median = 7, weil ebenso viele Fälle unterhalb wie oberhalb des sechsten Falles liegen ( $11 + 1 / 2 = 6$ , d.h. die sechste Beobachtung ist der Median)
- Beispiel 2 (gerade,  $n = 10$ ): 3, 4, 4, 5, **6**, **7**, 7, 8, 8, 9
- Hier ist der Median der halbierte Wert des 10/2-ten und des (10/2+1)-ten Falls, also  $= 6 + 7 / 2 = 6,5$

# Zentrale Tendenz

- Eigenschaften des Median:
  - Sinnvoll ab dem ordinalen Messniveau
  - Unempfindlich gegenüber Ausreißern
  - Mindestens 50% der Fälle sind kleiner oder gleich dem Median
  - Mindestens 50% der Fälle sind größer oder gleich dem Median

# Zentrale Tendenz

- Die bekannteste Maßzahl der zentralen Tendenz einer Verteilung ist der **arithmetische Mittelwert** ( $\bar{x}$ ), dessen Berechnung metrische Daten voraussetzt
- Das arithmetische Mittel ist definiert als die Summe der Messwerte, definiert durch ihre Anzahl:

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}$$

- Wenn Werte mehr als einmal vorkommen, kann man sie mit der Häufigkeit ( $f_i$ ) multiplizieren, mit der sie vorkommen:

$$\bar{x} = \frac{f_1 x_1 + f_2 x_2 + f_3 x_3 + \dots + f_k x_n}{n} = \frac{\sum_{i=1}^n f_i x_i}{n}$$

# Zentrale Tendenz


- Als Beispiel sei folgende Verteilung gegeben ( $n = 8$ ): 6, 7, 7, 8, 8, 8, 9, 9

$$\bar{x} = \frac{1(6) + 2(7) + 3(8) + 2(9)}{8} = \frac{62}{8} = 7,75$$

- Eigenschaften des arithmetischen Mittelwertes:
  - Berechnung setzt metrisches Messniveau voraus
  - Empfindlich gegen Ausreißer
  - „Schwerpunkteigenschaft“ (Summe der positiven und negativen Abweichungen vom arithmetischen Mittel = 0,  $\rightarrow$  Kovarianz):

$$\sum_{i=1}^n (x_i - \bar{x}) = 0$$

# Zentrale Tendenz



Anwendungsbeispiel

Fehlerbalken: 95%-Konfidenzintervall


# Zentrale Tendenz

- Keiner der Mittelwerte ist einem anderen in jeder Hinsicht überlegen und sollte universell verwendet werden
- Jeder reflektiert viel mehr einen anderen Aspekt einer Verteilung
- Der Modus gibt Aufschluss über die größte Häufigkeit, der Median über die mittlere Position und das arithmetische Mittel über die Zentralität der Werte
- Die Maße der zentralen Tendenz haben jedoch spezielle Eigenschaften, die mit der Form einer Verteilung zusammenhängen
- Ist eine Verteilung unimodal und exakt symmetrisch, sind Modus, Median und arithmetischer Mittelwert identisch

# Zentrale Tendenz


- Bei unimodalen rechtsschiefen (linkssteilen) Verteilungen besteht folgende Beziehung zwischen den Mittelwerten:  $\text{Modus} < \text{Median} < \text{Arithmetisches Mittel}$
- Bei linksschiefen (rechtssteilen) Verteilungen lautet die Beziehung:  $\text{Arithmetisches Mittel} < \text{Median} < \text{Modus}$
- Die wichtigste Schlussfolgerung daraus lautet: Der arithmetische Mittelwert reagiert stärker auf Ausreißer / Extremwerte als Median und Modus!
- Auf den nächsten Folien sind die genannten Eigenschaften der Maße der zentralen Tendenz dargestellt, wobei die vertikale y-Achse für die Häufigkeit und die horizontale x-Achse für eine mindestens ordinal skalierte Variable steht

# Zentrale Tendenz




Aus: Benninghaus (1998): Deskriptive Statistik, S. 50

# Zentrale Tendenz



Aus: Benninghaus (1998): Deskriptive Statistik, S. 50

# Zentrale Tendenz




Aus: Benninghaus (1998): Deskriptive Statistik, S. 50

# Streuung

- Die zentrale Tendenz gibt keinen Aufschluss über die Homogenität bzw. Heterogenität der Variablenwerte; hierzu benötigt man Streuungsmaße
- Die nächste Folie zeigt zwei Verteilungen der Wartezeit bis zum Eintreffen eines Taxis nach dem Anruf
- Bei beiden Taxiunternehmen betragen alle Maßzahlen der zentralen Tendenz 3 Minuten – nach Maßgabe dieser Kennziffern gibt es also keinen Unterschied


# Streuung

Unternehmen A



Arithmetischer Mittelwert: 3  
Median: 3  
Modus: 3

Unternehmen B



Arithmetischer Mittelwert: 3  
Median: 3  
Modus: 3

# Streuung

- Die Streuung der Verteilungen ist aber sehr unterschiedlich
- Die **Spannweite** (auch: Range) der Verteilung, definiert als die Differenz zwischen dem größten und kleinsten Wert, beträgt bei Unternehmen A 4 Minuten ( $5 - 1 = 4$ )
- Bei Unternehmen B beträgt sie dagegen 6 Minuten ( $6 - 0 = 6$ )
- Zudem kommt der zentrale Wert 3 bei Unternehmen A deutlich häufiger vor als bei Unternehmen B
- Bei Unternehmen A handelt es sich deswegen um eine steilgipflige Verteilung und bei Unternehmen B um eine flachgipfelige ( $\rightarrow$  Kurtosis)
- Wir suchen nun Koeffizienten, welche die Unterschiede in der Streuung erfassen

# Streuung

- Die gebräuchlichsten Streuungsmaße sind die **Standardabweichung (s)**, definiert als die Quadratwurzel aus der **Varianz (s<sup>2</sup>)**, die ihrerseits definiert ist als die durch die Anzahl der Messwerte (für Stichproben-  
daten: n-1) geteilte Summe der quadrierten Abweichungen aller  
Messwerte von ihrem arithmetischen Mittel:

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

- Varianz und Standardabweichungen setzen ein metrisches Messniveau voraus
- Zur Berechnung der beiden Kennwerte sind die folgenden Arbeitstabellen hilfreich:

# Streuung

Unternehmen A

$x_i$	$f_i$	$(x_i - \bar{x})$	$(x_i - \bar{x})^2$	$f_i(x_i - \bar{x})^2$
1	1	-2	4	4
2	2	-1	1	2
3	7	0	0	0
4	2	1	1	2
5	1	2	4	4
$\Sigma$	13			12

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} = \frac{12}{12} = 1 \qquad s = \sqrt{1} = 1$$

# Streuung

Unternehmen B

$x_i$	$f_i$	$(x_i - \bar{x})$	$(x_i - \bar{x})^2$	$f_i(x_i - \bar{x})^2$
0	1	-3	9	9
1	1	-2	4	4
2	2	-1	1	2
3	3	0	0	0
4	2	1	1	2
5	1	2	4	4
6	1	3	9	9
$\Sigma$	11			30

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} = \frac{30}{10} = 3 \quad s = \sqrt{3} = 1,73$$

# Streuung

- Die Varianz der Wartezeiten für Taxiunternehmen A liegt bei einer Quadratminute, wogegen sie für Unternehmen B drei Quadratminuten beträgt
- In der deskriptiven Statistik ist die Standardabweichung der Varianz vorzuziehen, weil sie ein Kennwert in der Messeinheit der zugrunde liegenden Variable ist (Minuten anstatt Minuten<sup>2</sup>)
- Die Standardabweichung (auch: durchschnittliche Abweichung vom Mittelwert) beträgt für Unternehmen A 1 Minute und für Unternehmen B 1,73 Minuten

# Streuung

## Anwendungsbeispiel

Tabelle: Religiöse Selbsteinstufung (1 = gar nicht religiös bis 10 = sehr religiös) in Abhängigkeit von konfessioneller Homogamie der Eltern


	N	Mittelwert	s
Konfessionelle Konstellation Eltern			
Beide konfessionslos	354	2.18	2.33
Gleiche Konfession	1807	5.78	2.96
Unterschiedliche Konfessionen	375	4.69	2.88
Insgesamt	2536	5.12	3.12

Quelle: ALLBUS 2002 (eigene Berechnungen)

# Streuung

- Wie zwei Variablen gemeinsam (in Abhängigkeit voneinander) streuen, zeigt das folgende **Streudiagramm**
  - Da die Variable Kirchengangshäufigkeit lediglich 6 diskrete Ausprägungen hat und die Variable religiöse Selbsteinstufung 10, wurden beiden Variablen bei der Erstellung des Diagramms kleine Zufalls-Fehler (Jitter) zugespielt
  - Die Anschaulichkeit und Aussagekraft von Streudiagrammen wird häufig durch die Einzeichnung von linearen oder nicht-linearen Anpassungslinien erhöht (→ Korrelation, Regression)

# Streuung



# Streuung

- Ein Heterogenitätsmaß für nominale oder ordinale Variablen ist der **Index qualitativer Variation**
- Grundidee: Der Index nimmt den Wert 0 an, wenn alle Fälle die gleiche Ausprägung aufweisen und den Wert 1, wenn die einzelnen Gruppen gleich stark besetzt sind
- Der Index kann nach folgender Formel berechnet werden ( $p_k^2$  ist die relative Häufigkeit der k-ten von m möglichen Klassen):

$$IQV = \frac{1 - \sum_{k=1}^m p_k^2}{\frac{1}{m} * (m - 1)}$$

# Streuung

## Konfession

ERHEBUNGSGEBIET: WEST - OST			Häufigkeit	Prozent	Gültige Prozente	Kumulierte Prozente
ALTE BUNDESLÄENDER	Gültig	katholisch	759	39,2	39,5	39,5
		evangelisch	772	39,9	40,2	79,7
		andere Religionsgemeinschaft	100	5,2	5,2	84,9
		keiner Konfession zugehörig	291	15,0	15,1	100,0
		Gesamt	1922	99,4	100,0	
	Fehlend	fehlender Wert	12	,6		
	Gesamt	1934	100,0			
NEUE BUNDESLÄENDER	Gültig	katholisch	58	6,5	6,6	6,6
		evangelisch	258	29,1	29,2	35,8
		andere Religionsgemeinschaft	12	1,4	1,4	37,1
		keiner Konfession zugehörig	555	62,6	62,9	100,0
		Gesamt	883	99,7	100,0	
	Fehlend	fehlender Wert	3	,3		
	Gesamt	886	100,0			


$$\text{IQV-West: } 1 - (0,395^2 + 0,402^2 + 0,052^2 + 0,151^2) / (1/4) * (4-1) = 0,656 / 0,75 = 0,87$$

$$\text{IQV-Ost: } 1 - (0,066^2 + 0,292^2 + 0,014^2 + 0,629^2) / (1/4) * (4-1) = 0,51 / 0,75 = 0,68$$


# Streuung

- Ein gebräuchliches Diagramm, das sowohl über die zentrale Tendenz als auch die Streuung einer Verteilung informiert, ist der **Box-Plot**
  - Die „Whisker“ (abgeleitet von Katzenschnurbart) kennzeichnen den größten bzw. kleinsten Wert, der noch keinen Ausreißer darstellt
  - Als Ausreißer gekennzeichnet sind Werte, die um mehr als das 1,5-fache der Boxhöhe (also um mehr als 1,5 Interquartilsabstände) über oder unterhalb der Box liegen
  - Werte, die um mehr als das 3-fache der Boxhöhe über oder unterhalb der Box liegen, gelten als Extremwerte und werden mit Sternen gekennzeichnet
  - Der Median muss nicht in der Mitte der Box liegen, seine Lage hängt von der Verteilung ab
  - Box-Plots werden meist eingesetzt, um die Verteilung einer mindestens ordinalen Variablen zwischen zwei oder mehr Gruppen zu vergleichen (siehe übernächste Folie)

# Streuung



# Streuung



# Höhere Momente

- Neben zentraler Tendenz und Streuung werden nun Koeffizienten für die sog. höheren Momente der Verteilung betrachtet: **Schiefe** und **Kurtosis**
- Der Schiefe-Koeffizient ist 0 bei symmetrischer, negativ bei rechtssteiler und positiv bei linkssteiler Verteilung
- Der vierte Moment einer Verteilung ist die sog. Kurtosis oder Wölbung; hohe Werte des Kurtosis-Koeffizienten indizieren steilgipflige Verteilungen mit hoher Wölbung
- Die nächsten Folien zeigen die Berechnungsformeln
  - Achtung: Statistikprogramme wie Excel oder SPSS rechnen unter Umständen mit anderen Formeln, die für den Stichprobenumfang adjustiert sind
  - Gelegentlich wird die Kurtosis einer Verteilung als Differenz zur Kurtosis der Standardnormalverteilung angegeben, die 3 beträgt


# Höhere Momente

- Die nachfolgenden Formeln zu Schiefe und Kurtosis basieren auf **z-standardisierten** Messwerten (→ Inferenzstatistik)
- Man erzeugt z-transformierte Werte  $z_i$ , indem man von jedem Messwert ( $x_i$ ) das arithmetische Mittel subtrahiert und diese Differenz durch die Standardabweichung ( $s$ ) dividiert:


$$z_i = \frac{x_i - \bar{x}}{s}$$

- z-transformierte Variablen haben einen Mittelwert von 0 und eine Standardabweichung von 1; dadurch werden die Schiefe- und Kurtosis-Koeffizienten unabhängig von der Messeinheit der jeweiligen Variablen


# Höhere Momente



Schiefe = 0  
(symmetrisch)




Schiefe = -0,75  
(rechtssteil)




Schiefe = 1,22  
(linkssteil)

$$\text{Schiefe} = \frac{\sum_{i=1}^n z_i^3}{n}$$

# Höhere Momente



Kurtosis = 2,61



Kurtosis = 1,73

$$Kurtosis = \frac{\sum_{i=1}^n z_i^4}{n}$$

# Übersicht: Zentrale Tendenz & Streuung

	<b>Maße der zentralen Tendenz</b>	<b>Streuungsmaße</b>
<b>Nominal</b>	Modus	Index qualitativer Variation
<b>Ordinal</b>	Modus, Median	Index qualitativer Variation
<b>Metrisch</b>	Modus, Median, arithmetischer Mittelwert	Spannweite, Interquartilsabstand, Standardabweichung, Varianz

Ohne Anspruch auf Vollständigkeit

# Übersicht: Einige Grafik-Typen

Betrachtung einer Variable (univariate Analyse):

<b>Nominal</b>	<b>Ordinal</b>	<b>Metrisch</b>
Balkendiagramm	Balkendiagramm, Box-Plot	Histogramm, Box-Plot

Betrachtung des Zusammenhangs zwischen zwei Variablen (bivariat):

	<b>Nominal</b>	<b>Metrisch (ordinal)</b>
<b>Nominal</b>	Gruppiertes Balkendiagramm	Box-Plot
<b>Metrisch (ordinal)</b>		Streudiagramm, Liniendiagramm

# Ausgewählte Literatur

- Benninghaus, H. (2007): Deskriptive Statistik: Eine Einführung für Sozialwissenschaftler. 11. Auflage. Wiesbaden: Springer VS.
- Kopp, J. & Lois, D. (2014): Sozialwissenschaftliche Datenanalyse. Eine Einführung. 2. Auflage. Wiesbaden: Springer VS (Kapitel 3).
- Müller-Benedict, V. (2006): Grundkurs Statistik in den Sozialwissenschaften. Wiesbaden: VS.