

Urliste oder **Rohdaten** sind die auszuwertenden Daten in der Form, wie sie nach der Datenerhebung vorliegen. Dimensionen der Urliste sind die **Fälle**, **Merkmale** und ihre **Ausprägungen**.

Voraussetzung für statistische Auswertung: jeder Fall besitzt in bezug auf jedes Merkmal genau eine Ausprägung

| Fälle | Merkmale | Ausprägungen |
|---|---|--|
| Ausgefüllte Fragebögen | Frage im Fragebogen | angekreuzte Antwort |
| mündl. interviewte Personen | Frage des Interviewers | Antwort-Kategorien |
| Texte | Beurteilungskriterien: z.B. Inhalt, Länge, Stil | Art des Inhalts, Zahl der Worte, ... |
| Beobachtete Objekte, z.B. Menschen im Lokal | Beobachtete Aktivitäten, z.B. trinken, sich unterhalten | Intensität der Handlung, z.B. Anzahl Biere, Anzahl der Gesprächspartner, ... |

Die **Häufigkeitsverteilung** (auch kurz „Verteilung“) eines Merkmals ist die Darstellung seiner Ausprägungen im Verhältnis ihres Auftretens in den Fällen.

20 Antworten auf: „Wie weit stimmen Sie mit der folgenden Meinung überein: Soziale Unterschiede sind gerecht“:
4,3,3,2,3,1,4,4,3,3,3,2,2,4,3,4,2,3,2,4
(1 = stimme voll zu, 2 = stimme eher zu, 3 = stimme eher nicht zu, 4 = stimme gar nicht zu)

Einkommen der 20 Befragten:
900,1600,800,2300,1300,2700,2100,2500,4000
1700,3300,1400,1900,1480,2900,1200,1150,
600,4100,2700

Messwertklassen sind die Zusammenfassungen von Ausprägungen zu Gruppen. Die sich daraus ergebenden Daten heißen **gruppierte Daten**.

Sei $f(X_k)$ die **absolute Häufigkeit** der Ausprägung k des Merkmals X bei N Fällen, dann ist

$p(X_k) = f(X_k) / N$ die **relative Häufigkeit** oder **Anteil** und

$\text{Proz}(X_k) = p(X_k) * 100$ die **prozentuale Häufigkeit**.

Dann gilt:

$$\sum_{\text{alle_}k} f(X_k) = N, \quad \sum_{\text{alle_}k} p(X_k) = 1.0,$$

$$\sum_{\text{alle_}k} \text{Proz}(X_k) = 100.0$$

Aufgaben der Statistik, mit Häufigkeitsverteilungen formuliert:

- Die Häufigkeitsverteilung mit mathematisch durch Formeln erzeugten Verteilungen zu vergleichen, die sich aus einer Theorie über die Daten ergeben.
- Die Häufigkeitsverteilung durch möglichst wenige Kennzahlen, sog. Parameter, ausreichend zu beschreiben.
- Die Häufigkeitsverteilungen zweier oder mehrerer Merkmale – u.a. mit Hilfe ihrer Kennzahlen – daraufhin zu vergleichen, ob sie in irgendeiner Weise miteinander verkoppelt sind.

Die **kumulierte Häufigkeitsverteilung F** gibt zu jedem Wert a des Merkmals X an, wie viele Fälle kleiner oder gleich diesem Wert a sind (als relative Häufigkeit).

$$F(a) = \sum_{X \leq a} p(X)$$

Verteilungsfunktion eines Merkmals heißt die Funktion F der kumulierten relativen Häufigkeiten. Sie hat 2 Eigenschaften:

1. Ihre Werte liegen zwischen 0 und 1.
2. Sie wächst monoton von 0 auf 1.

Soziale Unterschiede sind gerecht

| | | | Häufigkeit | Prozent | Gültige Prozente | Kumulierte Prozente | |
|--|--|----------|------------|------------------|------------------|---------------------|-------|
| | | | Gültig | STIMME VOLL ZU | 125 | 6,4 | 6,7 |
| | | BRD 1998 | | STIMME EHER ZU | 483 | 24,7 | 25,8 |
| | | | | ST.EHER NICHT ZU | 746 | 38,2 | 39,9 |
| | | | | ST.GAR NICHT ZU | 517 | 26,5 | 27,6 |
| | | | | Gesamt | 1871 | 95,9 | 100,0 |
| | | | | Missing | 81 | 4,1 | |
| | | | | Gesamt | 1952 | 100,0 | |

SOCIAL DIFFERENCES ARE ACCEPTABLE

| | | | Häufigkeit | Prozent | Gültige Prozente | Kumulierte Prozente | |
|--|--|----------|------------|-------------------|------------------|---------------------|-------|
| | | | Gültig | STRONGLY AGREE | 120 | ,4 | 8,6 |
| | | USA 1993 | | SOMEWHAT AGREE | 631 | 1,9 | 45,4 |
| | | | | SOMEWHAT DISAGREE | 474 | 1,5 | 34,1 |
| | | | | STRONGLY DISAGREE | 164 | ,5 | 11,8 |
| | | | | Gesamt | 1389 | 4,3 | 100,0 |
| | | | | Fehlend | 30907 | 95,5 | |
| | | | | NAP | 58 | ,2 | |
| | | | | NO OPINION | 26 | ,1 | |
| | | | | NA | 30991 | 95,7 | |
| | | | | Gesamt | 32380 | 100,0 | |


BRD 2014

V201 SOZIALE UNTERSCHIEDE SIND GERECHT

| | | Häufigkeit | Prozent | Gültige Prozent | Kumulative Prozente |
|---------|------------------------|------------|---------|-----------------|---------------------|
| Gültig | 1 STIMME VOLL ZU | 179 | 5,2 | 5,3 | 5,3 |
| | 2 STIMME EHER ZU | 905 | 26,1 | 26,6 | 31,8 |
| | 3 STIMME EHER NICHT ZU | 1593 | 45,9 | 46,8 | 78,6 |
| | 4 STIMME GAR NICHT ZU | 727 | 20,9 | 21,4 | 100,0 |
| | Gesamtsumme | 3404 | 98,1 | 100,0 | |
| Fehlend | 8 WEISS NICHT | 48 | 1,4 | | |
| | 9 KEINE ANGABE | 19 | ,5 | | |
| | Gesamtsumme | 67 | 1,9 | | |
| | Gesamtsumme | 3471 | 100,0 | | |

Balkendiagramm


Ein **Balkendiagramm** ist eine Darstellung einer Häufigkeitsverteilung von nominalen Daten in Säulenform, wobei sich die Säulen nicht berühren.






Grafiken
Grundprinzipien bei Grafiken

- ausreichend gekennzeichnet
- mathematisch genaue Umsetzung von Zahlen in grafische Objekte
- die Ausprägungen des Merkmals stehen auf der Abszisse (horizontale Achse, X-Achse)
- die Häufigkeiten jeder Ausprägung stehen auf der Ordinate (vertikale Achse, Y-Achse)

Histogramm

Ein **Histogramm** ist eine Darstellung einer Häufigkeitsverteilung von ordinalen oder gruppierten Daten in Säulenform, wobei die Säulen aneinander anschließen.





| Befragter | Einkommen | Soz.Unt. gerecht |
|-----------|-----------|------------------|
| 1 | 900 | 2 |
| 2 | 1600 | 4 |
| 3 | 800 | 3 |
| 4 | 2300 | 2 |
| 5 | 1300 | 4 |
| 6 | 2700 | 2 |
| 7 | 2100 | 3 |
| 8 | 2500 | 3 |
| 9 | 4000 | 2 |
| 10 | 1700 | 3 |
| 11 | 3300 | 4 |
| 12 | 1400 | 4 |
| 13 | 1900 | 2 |
| 14 | 1480 | 3 |
| 15 | 2900 | 4 |
| 16 | 1200 | 3 |
| 17 | 1150 | 3 |
| 18 | 600 | 4 |
| 19 | 4100 | 1 |
| 20 | 2700 | 3 |

Kreuztabelle zweier Merkmale

| | 1 Stimme voll zu | 2 Stimme eher zu | 3 Stimme eher nicht zu | 4 stimme gar nicht zu | Summe |
|----------------|------------------------|------------------------|---------------------------------|--------------------------------|-------|
| < 1500 | - | 1 | 4 | 3 | 8 |
| 1500 - 3000 | - | 3 | 4 | 2 | 9 |
| > 3000 | 1 | 1 | - | 1 | 3 |
| Summe | 1 | 5 | 8 | 6 | 20 |

In den jeweiligen Summenspalten einer Kreuztabelle stehen die beiden **Randverteilungen**. Es sind die Häufigkeitsverteilungen jedes der beiden Merkmale.

Jede **Zelle** in der Kreuztabelle enthält die Anzahl der Fälle, die die Ausprägung derjenigen beiden Merkmale besitzen, durch die die Zelle gebildet wird.

Die „Ursache“ bzw. „**unabhängige Variable**“ sollte in den Zeilen, die „Wirkung“ bzw. „**abhängige Variable**“ in den Spalten stehen.

Prozentuierungen, bedingte Verteilung

Um relative oder prozentuale Häufigkeiten zu bilden, hat man bei einer Kreuztabelle drei Möglichkeiten: man kann auf die Gesamtsumme der Fälle oder auf eine der beiden Randverteilungen prozentuieren. In den letzten beiden Fällen spricht man von **Zeilen- oder Spaltenprozenten**,

je nachdem, ob die Summen der Zeilen oder die Summen der Spalten die jeweiligen 100% bilden.

Die Verteilung eines Merkmals A unter der Bedingung, dass ein anderes Merkmal B eine bestimmte Ausprägung hat, heißt

bedingte Verteilung von A unter B


Beispiel Kreuztabelle

Kreuztabelle Einkommen*SOZIALE UNTERSCHIEDE SIND GERECHT

| | | SOZIALE UNTERSCHIEDE SIND GERECHT | | | | Gesamtsumme | |
|-------------|-------------------|-----------------------------------|----------------|----------------------|---------------------|-------------|--------|
| | | STIMME VOLL ZU | STIMME EHER ZU | STIMME EHER NICHT ZU | STIMME GAR NICHT ZU | | |
| Einkommen | unteres Drittel | Anzahl | 57 | 241 | 497 | 282 | 1077 |
| | | % in Einkommen | 5,3% | 22,4% | 46,1% | 26,2% | 100,0% |
| | mittleres Drittel | Anzahl | 44 | 251 | 478 | 244 | 1017 |
| | | % in Einkommen | 4,3% | 24,7% | 47,0% | 24,0% | 100,0% |
| Gesamtsumme | oberes Drittel | Anzahl | 46 | 302 | 454 | 121 | 923 |
| | | % in Einkommen | 5,0% | 32,7% | 49,2% | 13,1% | 100,0% |
| | | Anzahl | 147 | 794 | 1429 | 647 | 3017 |
| | | % in Einkommen | 4,9% | 26,3% | 47,4% | 21,4% | 100,0% |

Quelle: ALLBUS 2014


Gruppiertes Balkendiagramm



Müller-Benedict:Statistik I/2

21


3D-Säulendiagramm



Müller-Benedict:Statistik I/2

22

Streudiagramm (Beziehung zweier metrischer Merkmale)



Müller-Benedict:Statistik I/2

23

3-dimensionale Kreuztabelle

Kreuztabelle Einkommen*Soziale Unterschied gerecht?

% in Einkommen

| | | Soziale Unterschied gerecht? | | Gesamtsumme | |
|--|-----------|------------------------------|-----------------|-------------|--|
| | | stimme zu | stimme nicht zu | | |
| ERHEBUNGSGEBIET <WOHNGEBIET>: WEST - OST | Einkommen | unteres Drittel | | | |
| | | mittleres Drittel | | | |
| | | oberes Drittel | | | |
| | | Gesamtsumme | | | |
| ALTE BUNDES LAENDER | Einkommen | unteres Drittel | | 36,5% | |
| | | mittleres Drittel | | 63,5% | |
| | | oberes Drittel | | 100,0% | |
| | | Gesamtsumme | | 100,0% | |
| NEUE BUNDES LAENDER | Einkommen | unteres Drittel | | 14,9% | |
| | | mittleres Drittel | | 21,2% | |
| | | oberes Drittel | | 69,8% | |
| | | Gesamtsumme | | 100,0% | |

Müller-Benedict:Statistik I/2

24

Hausaufgabe:

Zum Nacharbeiten der Vorlesung vor den Hausaufgaben: Müller-Benedict, Kap. 4

Sie haben folgende Daten erhoben (s.Tabelle): für 15 Befragte das monatliche Nettoeinkommen (in €) und den formalen Schulabschluss.

- Stellen Sie die *absolute und relative Häufigkeitsverteilung* (nicht die Kreuztabelle) jeweils des Schulabschlusses und des Haushaltseinkommens dar, tabellarisch und grafisch. Gruppieren Sie dafür, wenn nötig, die Daten in *geeignete Messwertklassen*. Formulieren Sie eine kurze „Zeitungsmeldung“ über das Ergebnis.
- Zeichnen Sie die *kumulierte Verteilung* des Haushaltseinkommens möglichst genau („Haushaltseinkommen“ ist ein metrisches Merkmal!) auf.
- Gibt es eine Beziehung zwischen beiden Merkmalen? Wie können Sie das darstellen?

| Fall Nr. | Einkommen | Schulabschluss |
|----------|-----------|----------------|
| 1 | 5740 | Abitur |
| 2 | 4500 | Abitur |
| 3 | 2600 | Realschule |
| 4 | 2456 | Realschule |
| 5 | 4010 | Hauptschule |
| 6 | 3976 | Realschule |
| 7 | 7845 | Abitur |
| 8 | 2250 | Hauptschule |
| 9 | 1550 | Realschule |
| 10 | 1855 | Hauptschule |
| 11 | 3671 | Abitur |
| 12 | 1935 | Hauptschule |
| 13 | 3678 | Realschule |
| 14 | 1867 | Realschule |
| 15 | 3216 | Abitur |