






Deskriptive Statistik



KAD 2011.09.22



Element

Grundgesamtheit (Population):

Gesamtheit der Individuen (Elemente), deren Eigenschaften bei der Studie untersucht werden sollen. Die gesamte Menge der interessierenden Daten.

$N = \text{„unendlich“}$

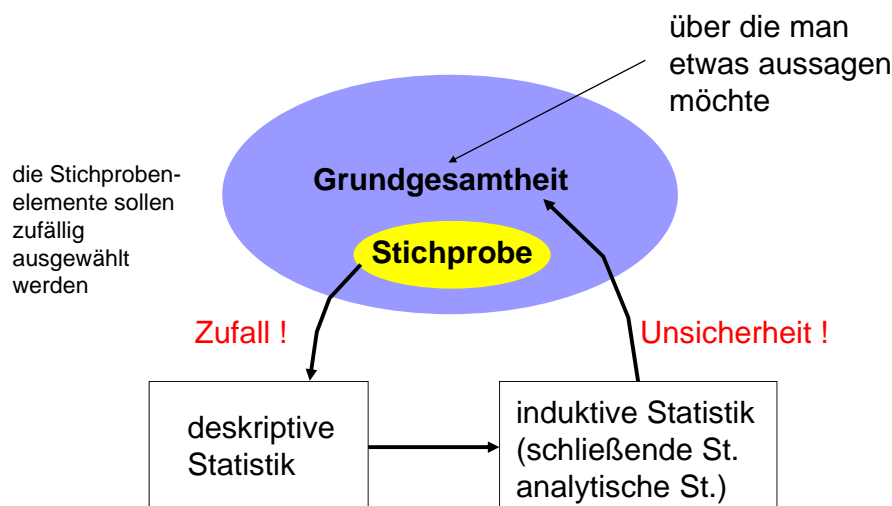
Stichprobe:

Der für die Studie ausgewählte Teil der Population.

$n = \text{endlich}$

$N \gg n$ (Umfang)

2



Die deskriptive Statistik ist die Vorstufe zur induktiven Statistik

3

Wie hoch ist die normale Pulsfrequenz (einer Population)?

Merkmal: Pulsfrequenz

zufällige Erhebung einiger

Elementen der Population: **Stichprobe**


Daten der Stichprobe liegen in Form einer Urliste vor:

66, 56, 89, 63, 66, 69, 71, 68, 58, 69, 78, 66, 64, 84, 74, 76, 69, 77, 74, 76 (Einheit: 1/Min),
oder:

66	56	89	63	66	69	71	68	58	69
78	66	64	84	74	76	69	77	74	76

„Die Werte sollen **geordnet** und **verdichtet** werden.“ !?

Stellen wir die Daten entlang einer Zahlengeraden dar!



4

Verfeinern wir die Klassen noch weiter!

Unterteilen wir die Zahlengerade in gleich breite Klassen (Intervalle) und zählen wir ab, wie viele Daten sich in den so erhaltenen **Klassen** befinden!

KLASSENGRENZEN	HÄUFIGKEIT
$55 \leq x_i < 60$	2
$60 \leq x_i < 65$	2
$65 \leq x_i < 70$	7
$70 \leq x_i < 75$	3
$75 \leq x_i < 80$	4
$80 \leq x_i < 85$	1
$85 \leq x_i < 90$	1
insgesamt:	$n = 20$

in Excel:

=frequency(...)
=Häufigkeit(...)


Die Grenzwerte und die Breiten der Klassen sind willkürlich. Stellen wir diese Treppenfunktion dar!

5

Häufigkeitsdichte

$$\frac{\Delta n}{\Delta x}$$

$$\left(\frac{1}{5 \frac{1}{\text{Min}}} \right) = \left(\frac{\text{Min}}{5} \right)$$



Die Fläche unter der Treppenfunktion zwischen 55 und 60:


$$5 \frac{1}{\text{Min}} \cdot 2 \frac{\text{Min}}{5} = 2$$

Die Gesamtfläche unter der Treppenfunktion: $20 = n$,

Anzahl der Messdaten in der Stichprobe


KLASSENGRENZEN	HÄUFIGKEIT
$55 \leq x_i < 60$	2
$60 \leq x_i < 65$	2
$65 \leq x_i < 70$	7
$70 \leq x_i < 75$	3
$75 \leq x_i < 80$	4
$80 \leq x_i < 85$	1
$85 \leq x_i < 90$	1
insgesamt:	$n = 20$

6



absolute

Häufigkeitsdichte-verteilung



relative

Fläche unter der Kurve:





n

Fläche unter der Kurve:

$$\frac{1}{n} n = 1 = 100\%$$

7


absolute Häufigkeitsdichte (Histogramm)



relative Häufigkeitsdichte (Histogramm)


„Jedes Rechteck entspricht einem Messwert.“





Pr.Buch Abb. 5

Bestimmung der optimalen Klasseneinteilung



optimale Klassenanzahl m :

$$m^2 = 2n$$

$$m = \sqrt{2n}$$


$$m = \sqrt{40} = 6.3$$

optimale Klassenbreite Δx :


$$\Delta x = \frac{x_{\max} - x_{\min}}{m}$$

$$\Delta x = \frac{89 - 56}{6.3} = 5.2$$


empirische Funktion



empirische Funktion



theoretische Funktion



Pr.Buch Abb. 6




n vergrößert sich, die Klassenbreite Δx kann verkleinert werden

Bei großen Stichproben ergibt die empirische Verteilungsfunktion eine sehr gute Näherung der theoretischen Verteilungsfunktion. (Die Stichprobe ist „gleich“ der Grundgesamtheit.)


10

Analyse von Häufigkeitsverteilungen


homogene symmetrische Stichprobe:



heterogene Stichprobe:



homogene nichtsymmetrische Stichproben:




linksschief




rechtsschief


Vermutung:



Gleichverteilung?



Normalverteilung?



Überlagerung von zwei Normalverteilungen?

Lagemasse, Lokationsmasse

Lageparameter. Charakterisierung des Zentrums der Daten

Durchschnittswert (der arithmetische Mittelwert)

=average(...)
=Mittelwert(...)

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

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

Die Summe der Abweichungen der Daten von diesem Wert ist gleich Null.

Modus (Modalwert, Dichtemittel): der Wert mit der größten Wahrscheinlichkeit; der häufigste Wert einer Häufigkeitsverteilung

=mode(...)
=Modalwert(...)

Median (Zentralwert): halbiert eine Stichprobe.

Anzahl der Daten der Stichprobe kleiner als Median = Anzahl der Daten der Stichprobe größer als Median

$$x_{\text{med}} = \begin{cases} x_{(n+1)/2} & \text{falls } n \text{ ungerade} \\ (x_{n/2} + x_{(n/2+1)})/2 & \text{falls } n \text{ gerade} \end{cases}$$


=median(...)
=Median(...)

12


Altersaufbau der deutschen Bevölkerung



Unimodal: die Verteilung hat nur einen Gipfel
 Bimodal: die Verteilung hat zwei Gipfel.
 Multimodal: die Verteilung hat mehrere Gipfel.



Linkssteile bzw. **rechtschiefe** Verteilung




z.B. Einkommensverteilungen in einem Land:

Der Großteil der Bevölkerung verdient relativ wenig, während es nur wenig Leute gibt, die sehr viel verdienen.


14

Weitere Beispiele

Maxwell-Boltzmann-Verteilung




Komplexität der Tiere



www.vordenker.de/it_gould/images/verteilung.gif

15


Linksschiefe bzw. rechtssteile Verteilung



z.B. Dauer einer Schwangerschaft



Daten und ihre Durchschnittswerte



Pr.Buch Abb. 10

17

Streuungsmaße (Variabilitätsmaße,
Variationsmaße)
Maß für die Streubreite von Daten

Streuungsparameter. Charakterisierung der Variation der Daten

Standardabweichung

(Streuung der
Messdaten, s):
die mittlere Abweichung
vom Durchschnitt:

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

=stdev(...)
=Stabw(...)

das Quadrat der Streuung,
die mittlere quadratische
Abweichung, auch als

Varianz bezeichnet:

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

=var(...)
=Varianz(...)

Spannweite: $x_{\max} - x_{\min}$

=max(...)-min(...)

18

α -Quantil

$$0 < \alpha < 1$$

(seien dazu die x_i aufsteigend sortiert):

$$x_{\alpha} = \begin{cases} x_{[n\alpha]+1} & \text{falls } n\alpha \text{ keine ganze Zahl ist} \\ (x_{n\alpha} + x_{n\alpha+1})/2 & \text{falls } n\alpha \text{ ganzzahlig ist} \end{cases}$$

$x_{1/4}$ – unteres Quartil $x_{3/4}$ – oberes Quartil

$x_{1/10}$ – unteres Dezil $x_{9/10}$ – oberes Dezil

halber Quartilabstand : $(x_{3/4} - x_{1/4})/2$

=Quantil(...)

mit Wörter: z.B. **Dezile**


Durch Dezile (lat. „Zehntelwerte“) wird die Verteilung in 10 gleich große Teile zerlegt. Unterhalb des dritten Dezils liegen 30 % der Verteilung.

19


Perzentilenkurven
sind ein Werkzeug
für den Arzt.

Wachstums- und
Gewichtskurven
für Mädchen

=percentile(...)
=Quantil(...)



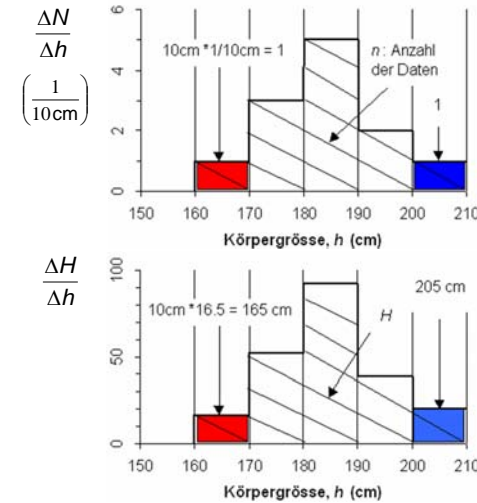
20




Skalentypen	zulässige Lage-Parameter	zulässige Streuungs-Parameter
Nominalskala	Modus	—
Ordinalskala	Modus, Median	—
numerische Skalen	Modus, Median, Durchschnittswert	Spannweite, Quartilabstand, Standardabweichung

21

Häufigkeitsverteilung




h : Körperhöhe
 H : kollektive Höhe, Gesamthöhe




Spektrum als eine spezielle Häufigkeitsverteilung

22

Häufigkeitsdichte




Spektrum



23


Emissionsspektrum:

wie verteilt sich die emittierte Energie über die Photonenenergien



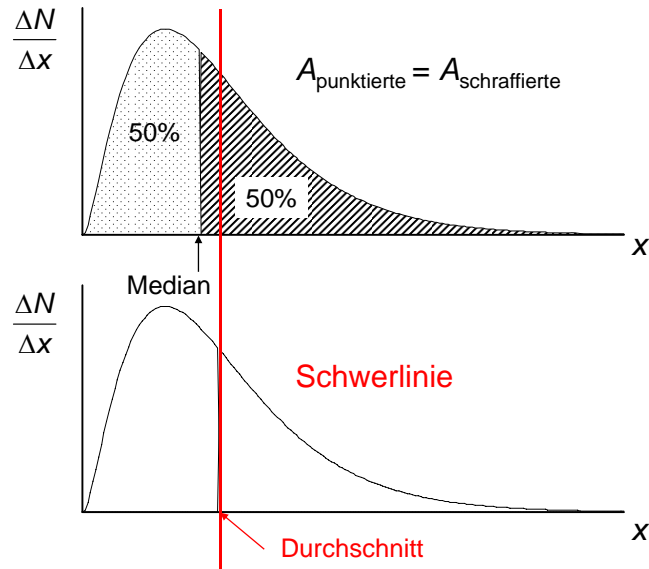
charakteristische Größe des Energietransports:
Intensität

Benützung der **Wellenlänge** ist bequemer als die der Photonenenergie




24

Position des Medians und des Durchschnitts einer Verteilung (1)



25


Position des Medians und des Durchschnitts einer Verteilung (2)



26

Summen- (kumulierte/kumulative) Häufigkeitsverteilung


Summen-
Häufigkeits-
verteilung



Wieviele
Werte sind
kleiner als h ?


$$\frac{\Delta N}{\Delta h} \left(\frac{1}{10 \text{ cm}} \right)$$

Häufigkeitsdichte-
Verteilung



DD-‐Spektrum‐‐


$M = N_0 - N$
„Summen-
Häufigkeits-
verteilung“



Wieviele
Werte sind
grösser als h ?

27

Quantile und die relative Summenhäufigkeits- verteilung



Coulter Zähler

	A	B	C	D	E	F	G	H	I	J
1	Counter counter									
2		ID	DD							
3		N	$\Delta N/\Delta V$							
4	V	1/V								
5	0.5	373	28							
6	1	359	20							
7	1.5	349	14							
8	2	342	36							
9	2.5	324	88							
10	3	280	120							
11	3.5	220	146							
12	4	147	110							
13	4.5	92	70							
14	5	57	48							
15	5.5	33	32							
16	6	17	16							
17	6.5	9	6							
18	7	6	4							
19	7.5	4	2							
20	8	3	2							
21	8.5	2	0							
22	9	2	0							
23	9.5	2	2							
24	10	1	2							
25										
26										
27										
28										

Figure 1 shows two plots. The top plot displays the dependence of N on U (V). The data points for ID (filled squares) and DD (open squares) show a sharp decrease in N as U increases from 0 to 10 V. The bottom plot displays the dependence of M/M_0 (1/V) on U (V). The data points for ID (filled squares) and DD (open squares) show a sharp decrease in M/M_0 as U increases from 0 to 10 V.