Deskriptive Statistik 1

KAD 2015.09.16

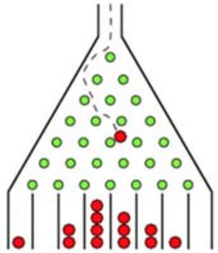

Die Statistik beschäftigt sich mit **Massenerscheinungen**, bei denen die dahinterstehenden Einzelereignisse meist zufällig sind.

Statistik benutzt die Methoden der Wahrscheinlichkeitsrechnung.

Fundamentalregeln:

Statistischen Aussagen beziehen sich nie auf ein Einzelereignis, sondern nur **auf Gesamtheiten vieler Ereignisse.**

Jede statistische Aussage ist mit einer **prinzipiell unvermeidlichen Unsicherheit** behaftet.

2

Wozu braucht eine Ärztin / ein Arzt Statistik?

— zum Verstehen der medizinischen Fachliteratur („How to Read a Paper") insbesondere von Originalarbeiten in Fachzeitschriften über
- experimentelle
- klinische
- epidemiologische
- sonstige (z. B. gesundheitsökonomische) Studien

— „Evidence-based Medicine" Bewertung und Kommunikation von Chancen und Risiken

— bei eigenen Untersuchungen
- Doktorarbeit
- Industrie
- Gesundheitsbehörden

http://www.medizin.uni-koeln.de/kai/imsie/kursinfo/q1/Q1-01-Einfuehrung.pdf

das erste Anwendungsgebiet der Statistik bestand in der **Staatsbeschreibung** (Völkszählung) *Status* = Zustand

Semmelweis (1818-1865) war der erste bekannte Arzt, der den Nutzen einer neuen Therapie **mit statistischen Methoden** belegte

4

Was messen Physiker, Arzt und Medizinstudent?

WER MISST WAS?		
PHYSIKER	ARZT	MEDIZINSTUDENT IM PHYSIKPRAKTIKUM
Länge	Körpergröße	Durchmesser von Erythrozyten (3)
Frequenz	Pulsfrequens	Impulshäufigkeit (9,20)
Temperatur	Körpertemperatur	—
Konzentration	Blutzuckerspiegel	Eiweißkonzentration im Blutplasma (5)
Spannung	EKG-Signal	EKG-Signal (24)
Leistungsdichte	Hörschwelle	Hörschwelle (22)
Druck	Blutdruck	—
Impedanz	Hautimpedanz (Hautwiderstand)	Hautimpedanz (21)

Pr.Buch Tabelle 3

Labormessergebnisse

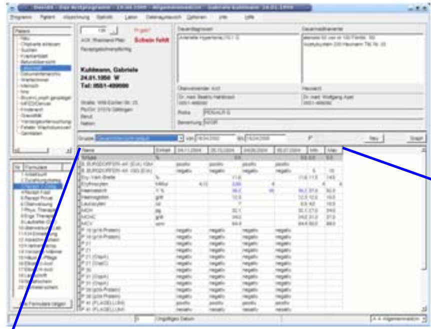

Name	Einheit	04.11.2004	05.10.2004	04.08.2004	05.07.2004	Min	Max
%Hypo	%		0.5		0.5	0.0	5.0
B. BURGDORFERI-AK (EIA) IGM		positiv	positiv	positiv	positiv		
B. BURGDORFERI-AK IGG (EIA)		negativ	negativ	negativ	negativ	5	10
Ery.-Vert.-Breite	%		11.6		11.6	11.5	14.5
Erythrozyten	Mill/ul	4,12	3,95	4		4	6
Haematokrit	V %		36.2	36	36.2	37.0	52.0
Haemoglobin	g/dl		12.3		12.3	12.0	16.0
Leukozyten	/ul		7		6.5	4.0	10.0
MCH	pg		32.1		32.1	27.0	34.0
MCHC	g/dl		34.0		34.0	31.0	37.0
MCV	ucm		94.4		94.4	80.0	99.0
P 18 (p18-Protein)		negativ	negativ	negativ	negativ		

Klassifizierung der Merkmale

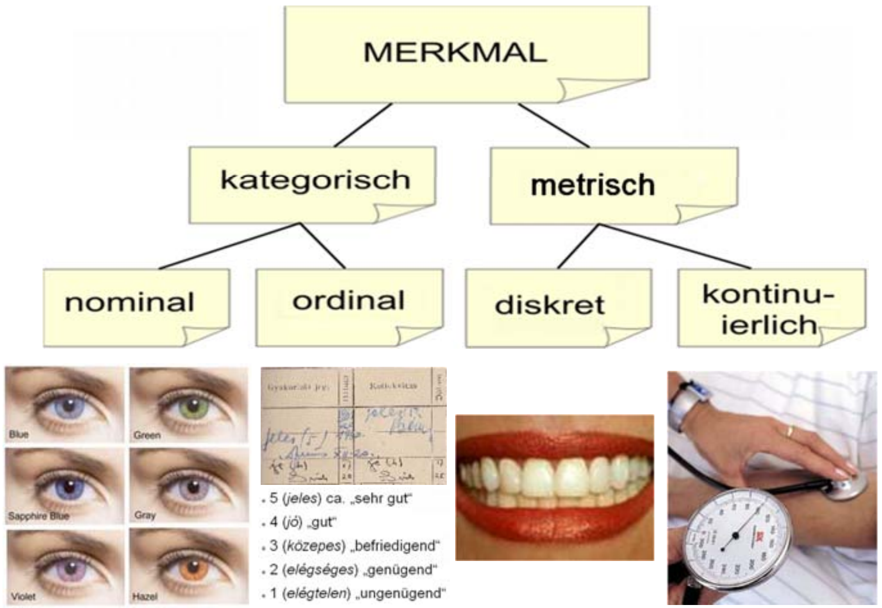

Skalentypen der metrischen Merkmale

	diskret	kontinuierlich
Intervall-skala definierte Differenz, „kein” 0 Punkt	Tage in einem Kalender 	Tempe-ratur in °C 
Verhältnis-skala definiertes Verhältnis, 0 Punkt	Anzahl der Zähne 	Tempe-ratur in K 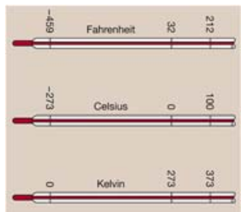

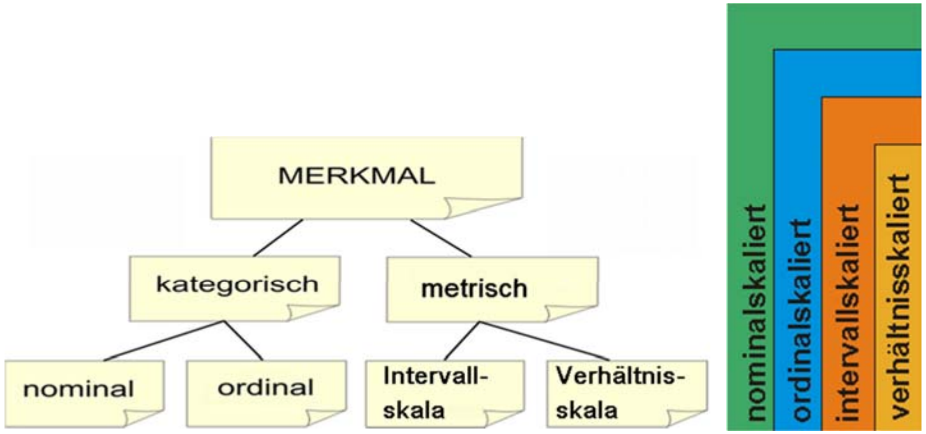

nominal	ordinal	Intervallskala	Verhältnisskala	
=, ≠	=, ≠	=, ≠	=, ≠	**Auseinander-halten**
	<, >	<, >	<, >	**Anordnung**
		+, –	+, –	**Differenz**
			*, /	**Verhältnis**

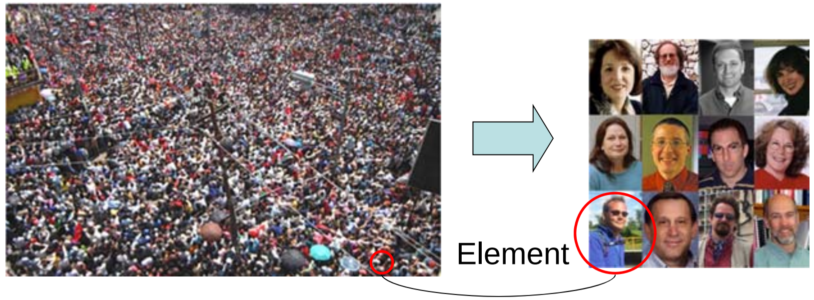

Grundgesamtheit (Population):

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

N = „unendlich”

Stichprobe:

Der für die Studie ausgewählte Teil der Population.

n = endlich

N >>*n* (Umfang)

die Stichproben-elemente sollen zufällig ausgewählt werden

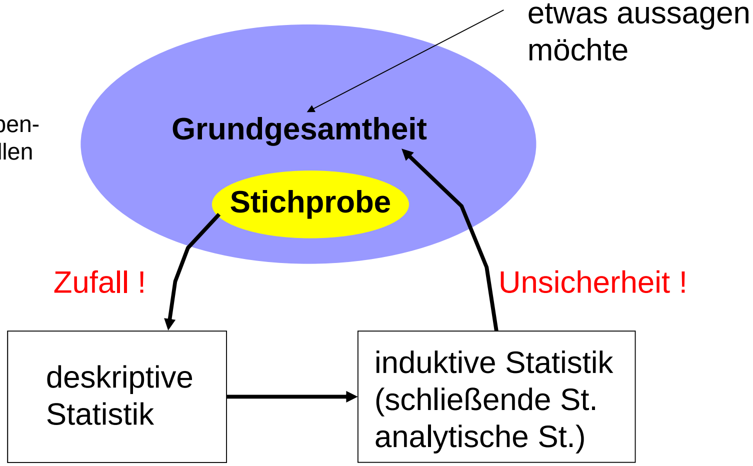

Die deskriptive Statistik ist die Vorstufe zur induktiven Statistik

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!

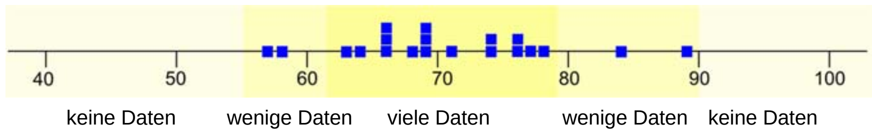

Pr.Buch Abb. 4

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!

Pr.Buch Tabelle 5

Häufigkeitsdichte

$$\frac{\Delta n}{\Delta x} \quad \left(\frac{1}{5\frac{1}{\text{Min}}}\right) = \left(\frac{\text{Min}}{5}\right)$$

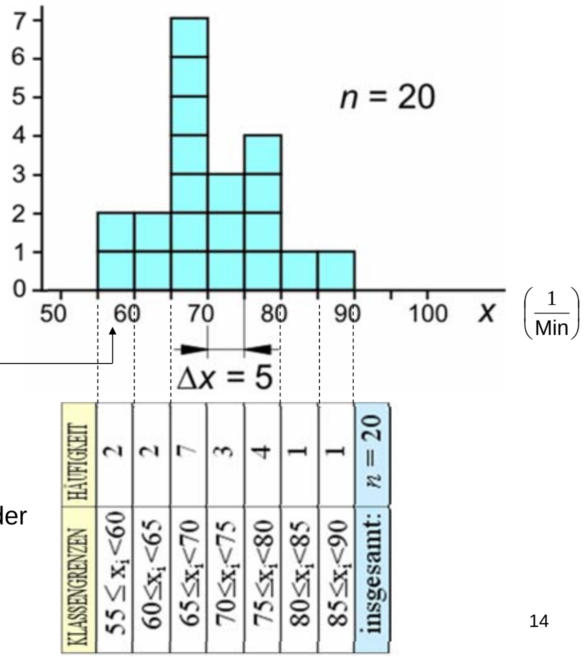

Die Fläche unter der Treppenfunktion zwischen 55 und 60:

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

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

Anzahl der Messdaten in der Stichprobe

$$\frac{\Delta n}{\Delta x} \quad \left(\frac{\text{Min}}{5}\right)$$

absolute

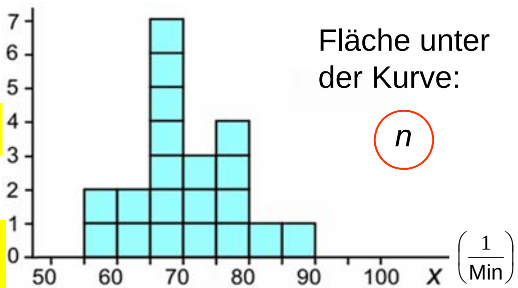

Fläche unter der Kurve:

n

Häufigkeitsdichte-verteilung

$$\frac{1}{n}\frac{\Delta n}{\Delta x} \quad \left(\frac{1}{20}\,\frac{\text{Min}}{5}\right)$$

relative

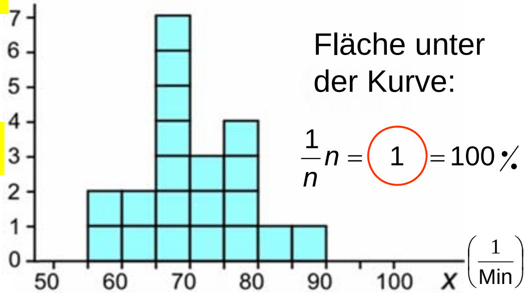

Fläche unter der Kurve:

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

absolute Häufigkeits-dichte
(Histogramm)

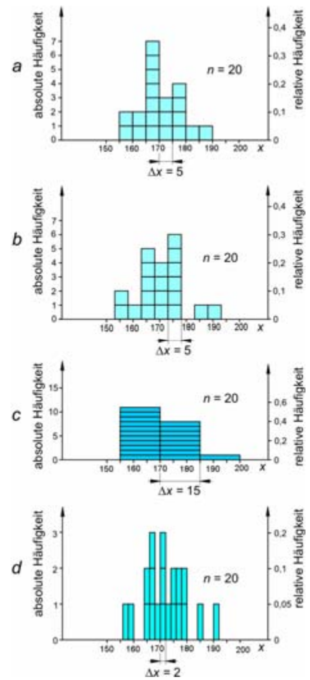

relative Häufigkeits-dichte
(Histogramm)

„Jedes Rechteck entspricht einem Messwert. „

Pr.Buch Abb. 5

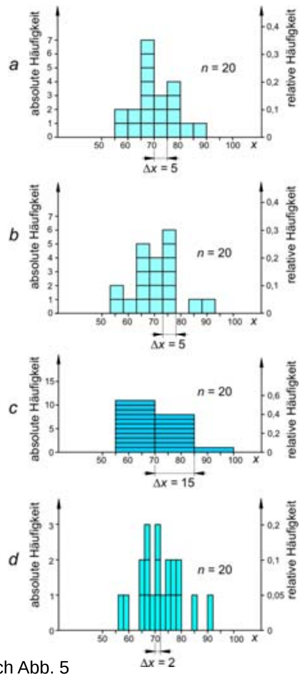

Pr.Buch Abb. 5

Bestimmung der optimalen Klasseneinteilung

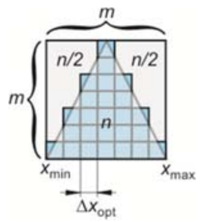

optimale Klassenanzahl m:

$$m^2 = 2n$$

$$m = \sqrt{2n} \qquad m = \sqrt{40} = 6.3$$

optimale Klassenbreite Δx:

$$\Delta x = \frac{x_{max} - x_{min}}{m} \qquad \Delta x = \frac{89 - 56}{6.3} = 5.2$$

empirische Funktion

empirische Funktion

theoretische Funktion

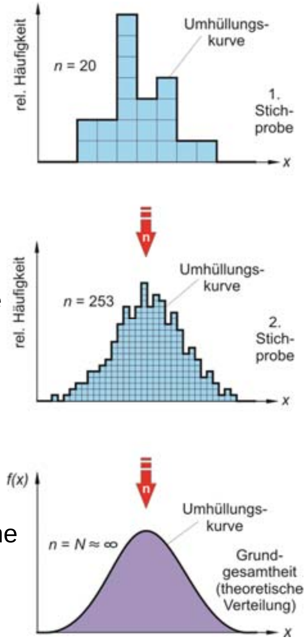

Pr.Buch Abb. 6

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.)

Beispiel: Biophysik Praktikum, Mikroskop

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R
1	calibr. um/o.u.	2.5			total		N1 2009.09.23		Moritz	Pia+ Lud	Isabella	Jan, Luk	Stefanie	Fre, Bas,	Simon,	Melina,	Jana,	Natalie,
2					um	o.u.	unit		o.u.	o.u.	o.u.	o.u.	o.u.	o.u.	o.u.	o.u.	o.u.	o.u.
3	confidence int.				22	8.8	average		10	8.4	8.3	8.6	8.6	9.1	8.4	9.1	8.8	8.4
4	95% data, um		95% data, o.u		3.68	1.47	stdev		1.5	1.4	1.3	1.1	1.9	1	1.2	1.3	1.6	1.3
5	14.6	29.4	5.9	11.7	0.18	0.07	s.e.m		0.2	0.2	0.2	0.2	0.3	0.1	0.2	0.2	0.2	0.2
6	95% avg, um		95% avg, o.u.		7.5	3	min		6	6	4	6	3	7	6	6.5	5	5
7	21.6	22.4	8.7	8.9	37.5	15	max		15	11	10	12	15	11	11	12	12	11
8									1	2	3	4	5	6	7	8	9	10
9								1	10	10	9	9	10	10	8	11	8	10
10								2	9.5	9	7	8	9	9	9	9	11	8
11								3	10	10	7	10	10	9	10	8	9	9
12								4	9	8	8	9	10	8	9	9	8	10
13								5	10	7	10	8	8	9	7	9.5	10	8
14								6	10	9	6	8	11	9	8	11	9	8
15								7	10	9	7	8	8	9	9	9.5	10	7
16								8	11	8	8	10	11	11	10	10	12	8
17								9	11	8	9	9	10	8	8	9	9	9
18								10	6	6	8	8	8	9	9	10	10	9
19								11	10	9	9	7	10	10	8	11	10	10
20								12	11	11	9	8	8	8	11	10	8	6
21								13	11	7	7	8	10	9	8	11	11	9
22								14	9	9	9	9	9	8	11	7	9	8
23								15	11	9	6	9	11	9	8	11	7	8
24								16	12	8	4	10	15	10	10	9	10	5
25								17	10	10	7	9.5	8	9	9	10	10	10
26								18	8	7	10	9.5	9	7	8	10	9	9
27	bin				freq	rel. fr.	Gauss	19	11	9	8	9	8	7	9	9	9	10

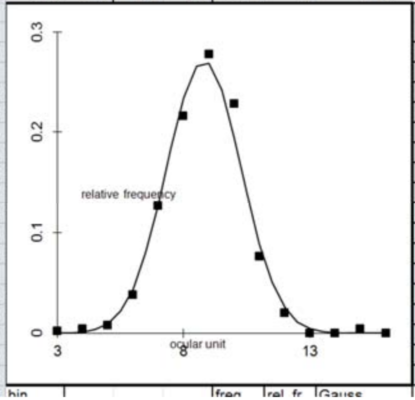

Analyse von Häufigkeitsverteilungen

homogene symmetrische Stichprobe:

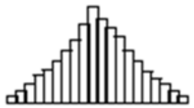

heterogene Stichprobe:

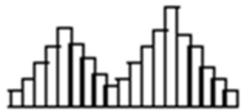

homogene nichtsymmetrische Stichproben:

linksschief

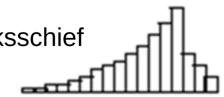

rechtsschief

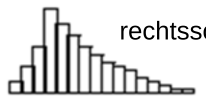

Vermutung:

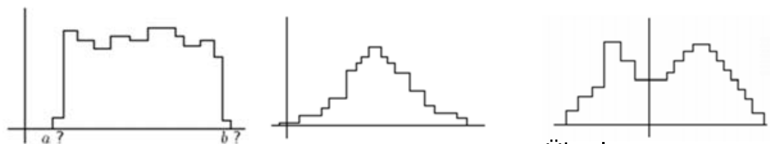

Gleichverteilung? Normalverteilung? Überlagerung von zwei Normalverteilungen?