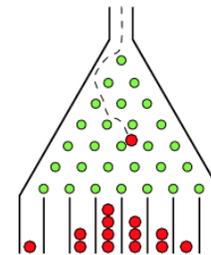




Deskriptive Statistik

KAD 2013.09.12



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** (Völkzählung) *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	Pulsfrequenz	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)


5

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. BURGENDORFERI-AK (EIA) IGM		positiv	positiv	positiv	positiv			
B. BURGENDORFERI-AK IGG (EIA)		negativ	negativ	negativ	negativ	5	10	
Ery.-Vert.-Breite	%		11,6			11,6	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	16,0	
Leukozyten	/ul		7			6,5	10,0	
MCH	pg		32,1			32,1	34,0	
MCHC	g/dl		34,0			34,0	37,0	
MCV	ucm		94,4			94,4	99,0	
P 18 (p18-Protein)		negativ	negativ	negativ	negativ			

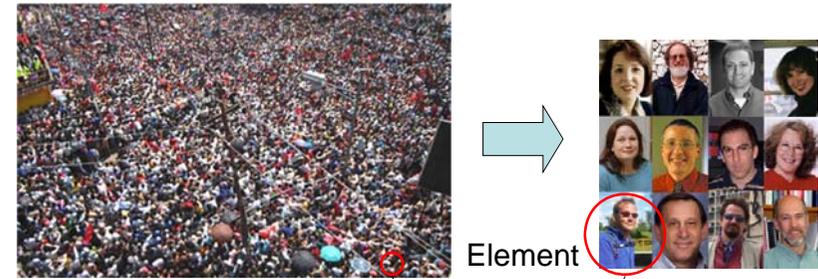
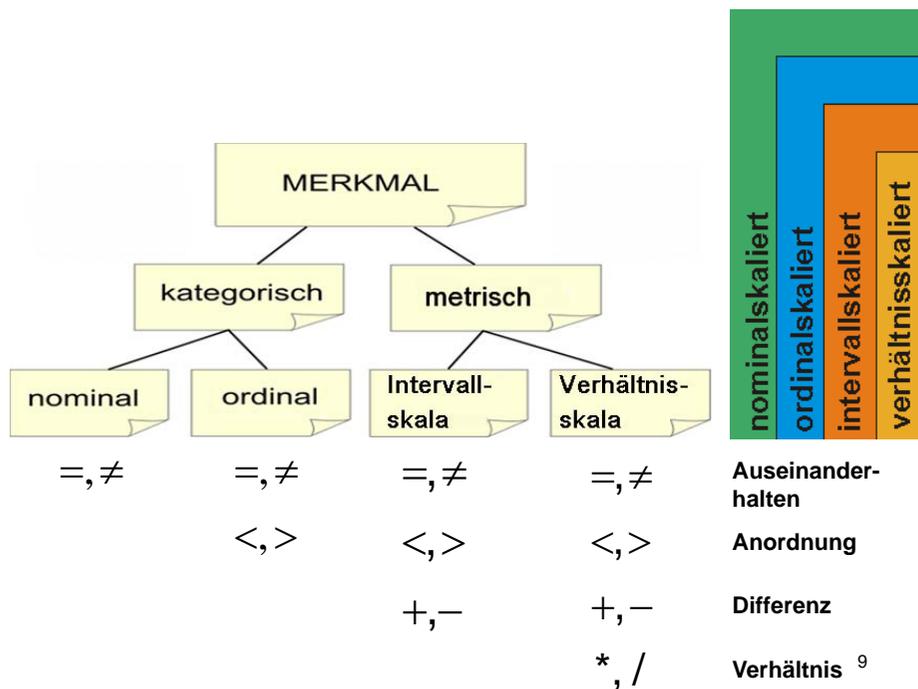
Klassifizierung der Merkmale



Skalentypen der metrischen Merkmale

	diskret	kontinuierlich
Intervallskala definierte Differenz, „kein“ 0 Punkt	Tage in einem Kalender 	Temperatur in °C
Verhältnisskala definiertes Verhältnis, 0 Punkt	Anzahl der Zähne 	Temperatur in K

8



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)



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**

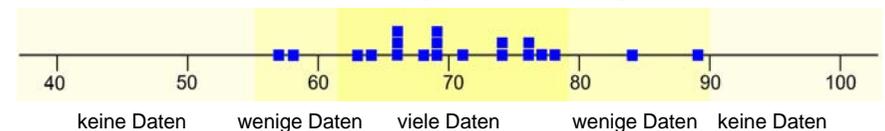
Daten der Stichprobe liegen in Form einer Urliste vor:

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!



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!

KLASSENRENZEN	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!

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

KLASSENRENZEN	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:	$n = 20$

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

absolute

**Häufigkeitsdichte-
verteilung**

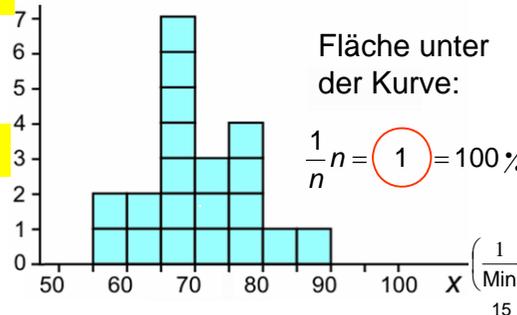


Fläche unter der Kurve:

n

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





relative



Fläche unter der Kurve:

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


**absolute
Häufigkeits-
dichte
(Histogramm)**




**relative
Häufigkeits-
dichte
(Histogramm)**



„Jedes Rechteck entspricht einem Messwert.“



Bestimmung der optimalen Klasseneinteilung



optimale Klassenanzahl m :

$$m^2 = 2n$$


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

optimale Klassenbreite Δx :


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

Pr.Buch Abb. 5


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.)

Analyse von Häufigkeitsverteilungen

homogene symmetrische Stichprobe:




heterogene Stichprobe:




homogene nichtsymmetrische Stichproben:


linksschief




rechtsschief




Vermutung:



Gleichverteilung?



Normalverteilung?



Überlagerung von zwei Normalverteilungen?

Lageparameter. Charakterisierung des Zentrums der Daten

Durchschnittswert (der arithmetische Mittelwert)

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

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

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(...)

Durchschnittswert (der arithmetische Mittelwert)




$\sum_{i=1}^n (x_i - \bar{x}) = \sum x_i - \sum \bar{x} = \sum x_i - n\bar{x} = 0$ Die Summe der Abweichungen der Daten von diesem Wert ist gleich Null.

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

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

21

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.


22

Weitere Beispiele

Maxwell-Boltzmann-Verteilung




Komplexität der Tiere



23

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


Linksschiefe bzw. rechtssteile Verteilung



z.B. Dauer einer Schwangerschaft



Daten und ihre Durchschnittswerte



Pr.Buch Abb. 10

25

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(...)

26

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.

27


Perzentilenkurven sind ein Werkzeug für den Arzt.

Wachstums- und Gewichtskurven für Mädchen

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




28



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

29


Position des Medians und des Durchschnitts einer Verteilung



30


Summen- (kumulierte/kumulative) Häufigkeitsverteilung

Summen-Häufigkeitsverteilung




Wieviele Werte sind kleiner als h ?

Häufigkeitsdichte-Verteilung




„Summen-Häufigkeitsverteilung“



Wieviele Werte sind grösser als h ?

31

Coulter-Zähler



LYMPH% 16.2 %
 MXD % 6.7 %
 NEUT% 77.1 %
 LYMPH# $1.2 \times 10^3 / \mu\text{L}$
 MXD # $0.5 \times 10^3 / \mu\text{L}$
 NEUT# $5.8 \times 10^3 / \mu\text{L}$

