

Wie fühlen Sie sich heute? 1 unter 100, 1%, oder ganz einfach 0,01?



## Deskriptive Statistik

Wie können Sie effizient naturwissenschaftlichen lernen?

Naturwissenschaft ist wie eine Sprache: am besten übt man, und versucht neue dinge zu verstehen.

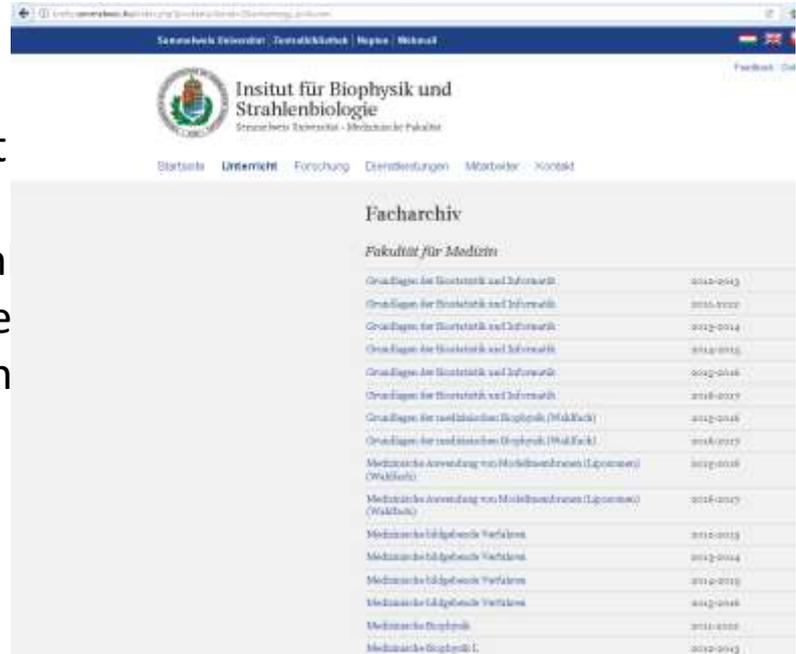
Was unverständlich scheint, das schaut man nochmal durch, solange bis man es wenigstens ein bisschen benutzen kann.

Lassen Sie nie eine Frage offen länger als eine Woche!

Sie können während der Vorlesung und Praktika ihre Fragen stellen, wir versuchen die zu beantworten.

Kommen sie zu der Vorlesungen mit unter

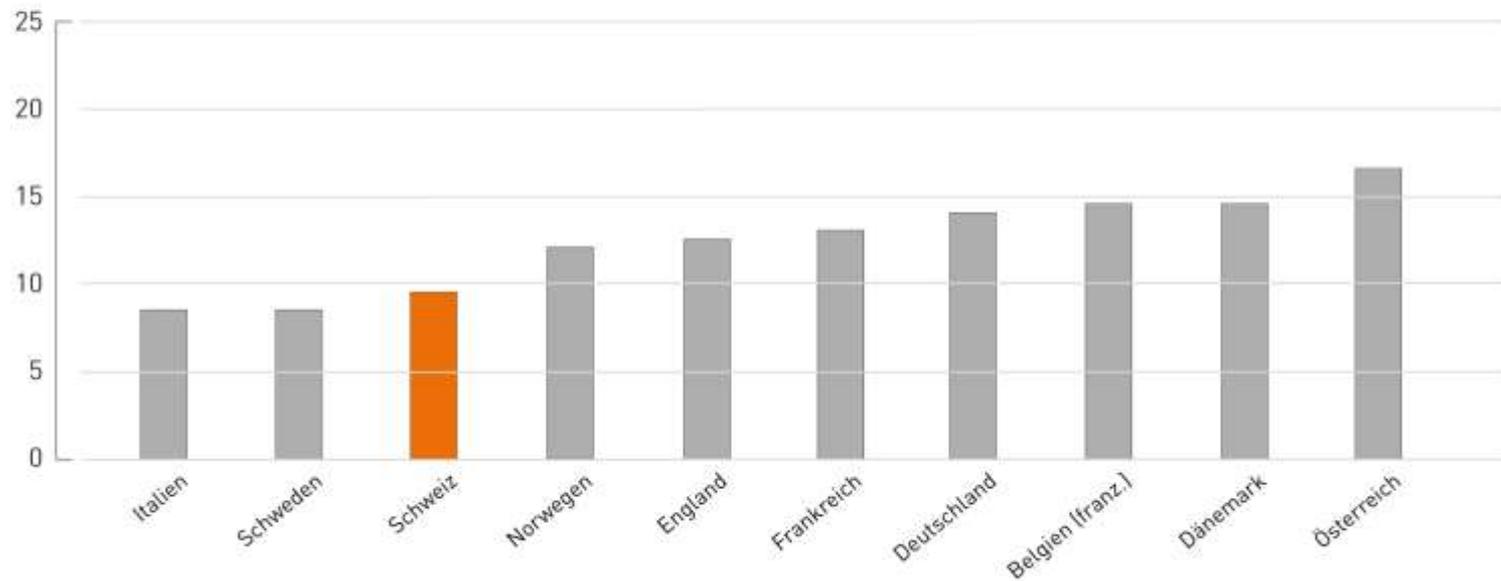
<http://biofiz.semmelweis.hu> erreich  
Falls nicht in dem aktuellen Semeste  
vorigen Jahr mit, die Veränderungen



## Statistik ist auch in der Zahnmedizin...

### Differenz in der Häufigkeit des mehrmals täglichen Zähneputzens

- ▶ zwischen Kindern aus Familien mit niedrigem und mit hohem Einkommen, in Prozentpunkten (2013/2014)



Quelle: HBSC Survey  
[www.economiesuisse.ch](http://www.economiesuisse.ch)



Die Statistik beschäftigt sich mit  
**Massenerscheinungen,**  
aber

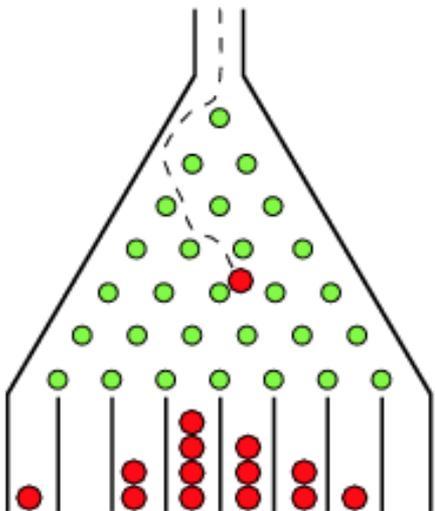
Einzelereignisse sind am meisten zufällig

Statistik benutzt die Methoden der  
Wahrscheinlichkeitsrechnung.

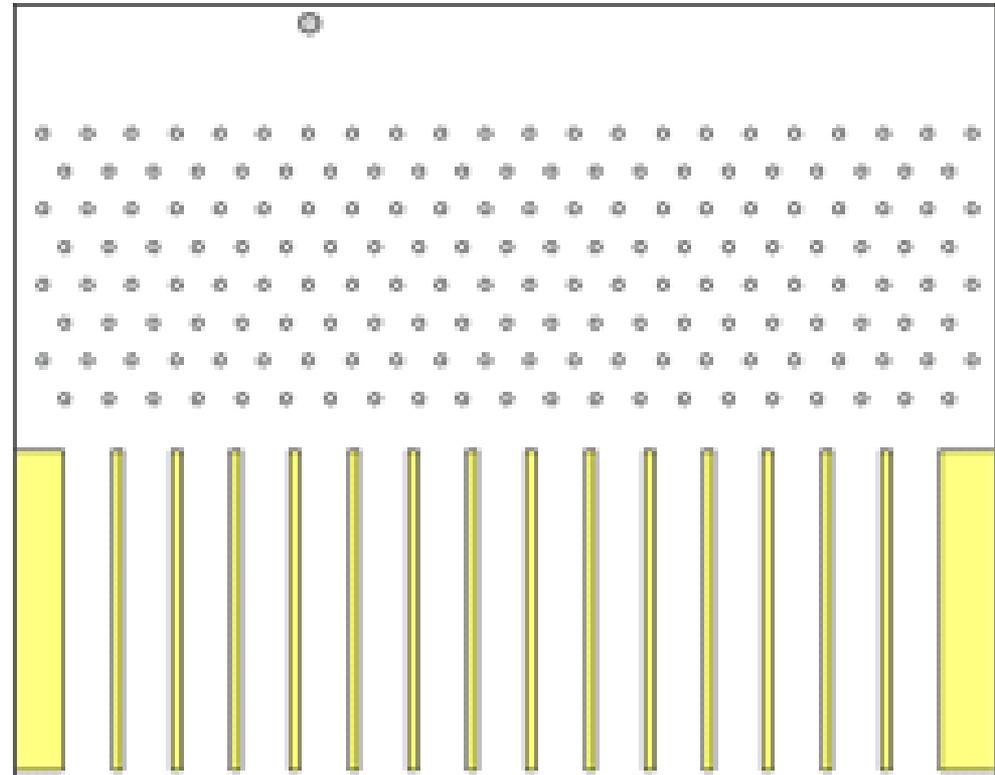
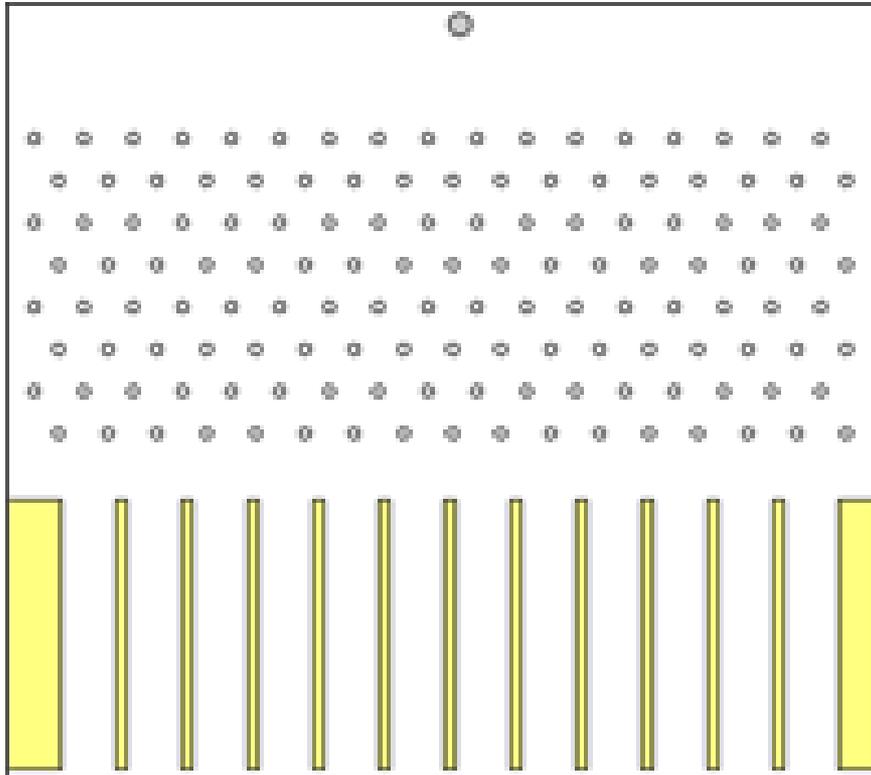
*Fundamentalregeln:*

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

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



## Galton'sches Brett

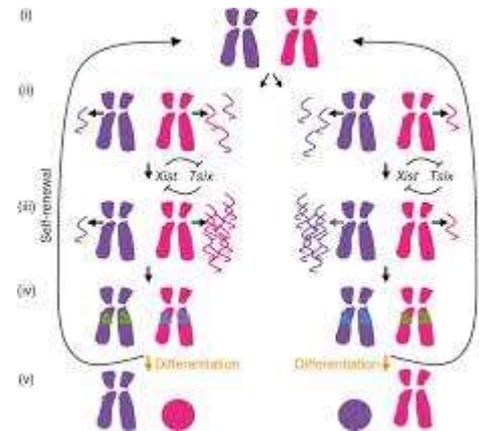


Die einzelnen Kugeln können wir theoretisch folgen, aber doch **nicht vorhersagen** welchen Vortritt sie nehmen, trotzdem, ein **durchschnittliches Benehmen** können wir beobachten.

## Federteile und Blütenblätter



Zufälligkeit ist überall in der Natur



Gene



Blitze

Doch: wir sehen auch Ordnung...



Blätter

Statistik versucht Konzepte hinter, und in der Zufälligkeiten zu finden.

Oft „das grosse Bild“ zeigt etwas „sinnvolles“, wobei die einzelnen Elemente anscheinend rein zufällig sind.



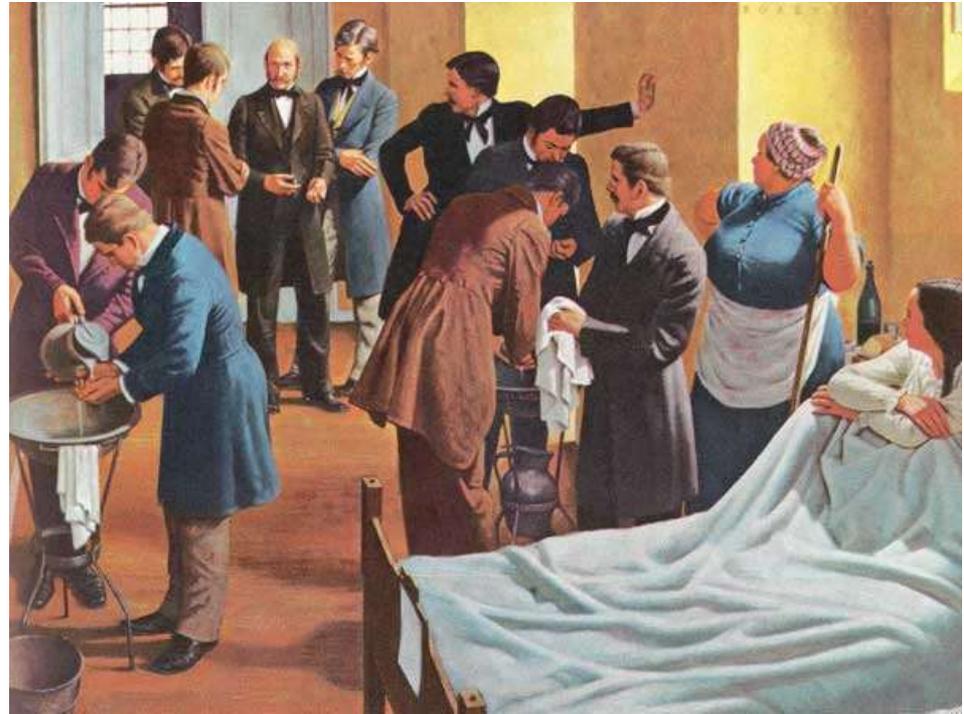
# Wozu braucht eine Ärztin / ein Arzt Statistik?

- 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**

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



# 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	Glycerinkonzentration der Lösung (5)
Spannung	EKG-Signal	EKG-Signal (24)
Leistungsdichte	Hörschwelle	Hörschwelle (22)
Druck	Blutdruck	—
Impedanz	Hautimpedanz (Hautwiderstand)	Hautimpedanz (21)

# Labormessergebnisse

**Patient:** Kuhlmann, Gabriele  
 24.01.1950 W  
 Tel: 0551-499090  
 Adresse: Wb-Ordnr Str. 23  
 72074 27004 Göttingen  
 Telefon: 0551-499090

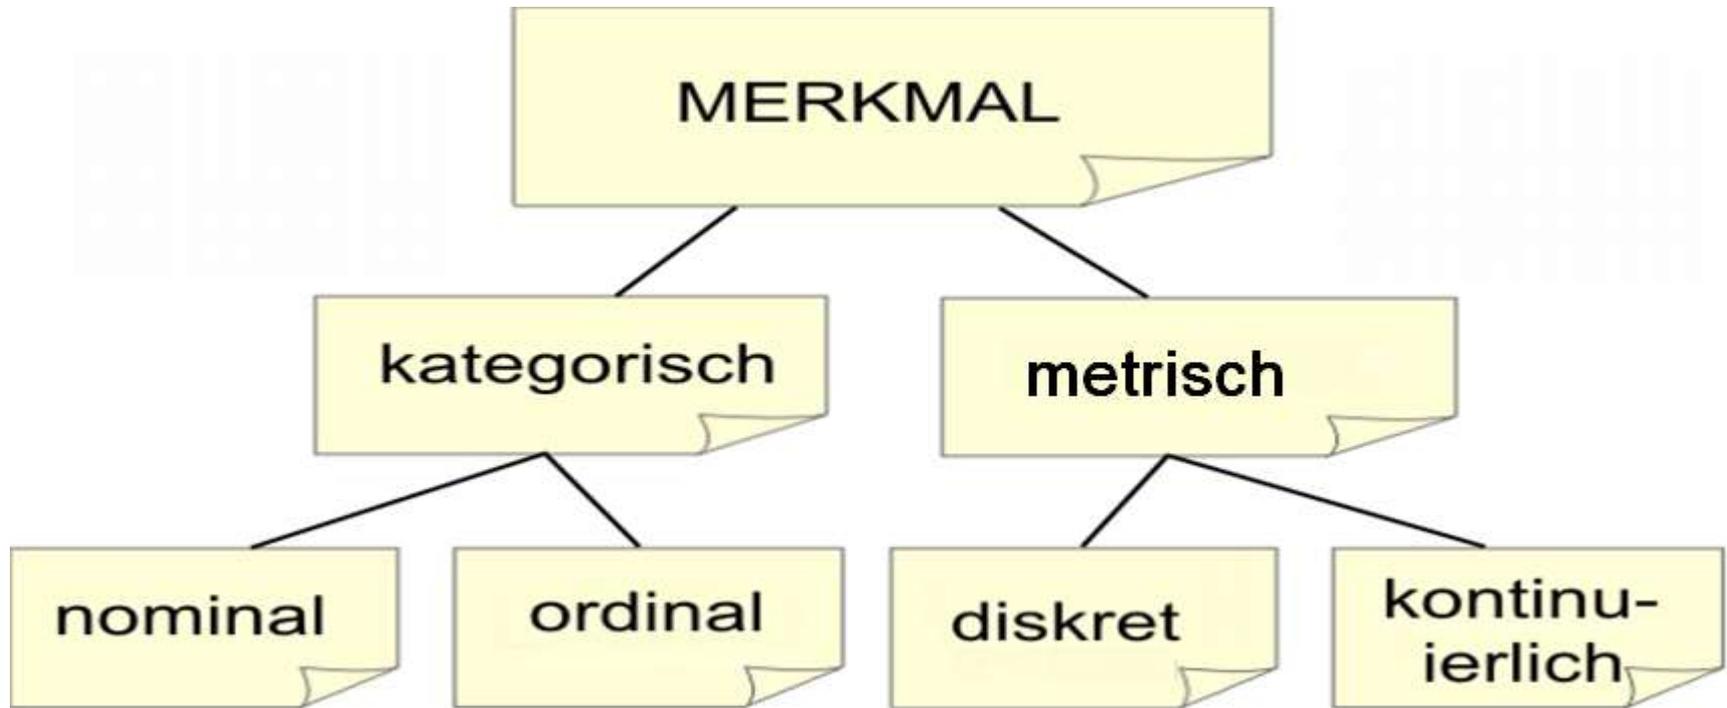
**Diagnosen:** Anämie Hyperferrit(EM) S  
**Diagnostik:** Anämie S3 von 100 Ferrit, IG  
 Anämie Typen 200 Heuerm T3, Fe, Z3

**Überwachen Arzt:** Hausarzt  
**Di. med. Dienst:** Dr. med. Beate Hoffmann (0551-499090)  
**Di. med. Stellungsp. Arzt:** Dr. med. Beate Hoffmann (0551-499090)

**Gruppe:** 15342002 | **Ver:** 15342002 | **Am:** 04.08.2004

Name	Einheit	04.11.2004	05.10.2004	04.08.2004	05.07.2004	Min	Max
%Hypo	%			0.5		0.5	0.0
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
Erythrozyten	Mill/ul	4,12	3,95	4			4
Haematokrit	V %		36.2	36		36.2	37.0
Haemoglobin	g/dl		12.3			12.3	12.0
Leukozyten	/ul		7			6.5	4.0
MCH	pg		32.1			32.1	27.0
MCHC	g/dl		34.0			34.0	31.0
MCV	ucm		94.4			94.4	80.0
P 18 (p18-Protein)		negativ	negativ	negativ	negativ		

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
Erythrozyten	Mill/ul	4,12	3,95	4			4
Haematokrit	V %		36.2	36		36.2	37.0
Haemoglobin	g/dl		12.3			12.3	12.0
Leukozyten	/ul		7			6.5	4.0
MCH	pg		32.1			32.1	27.0
MCHC	g/dl		34.0			34.0	31.0
MCV	ucm		94.4			94.4	80.0
P 18 (p18-Protein)		negativ	negativ	negativ	negativ		



Übung mit Komparativ und Superlativ

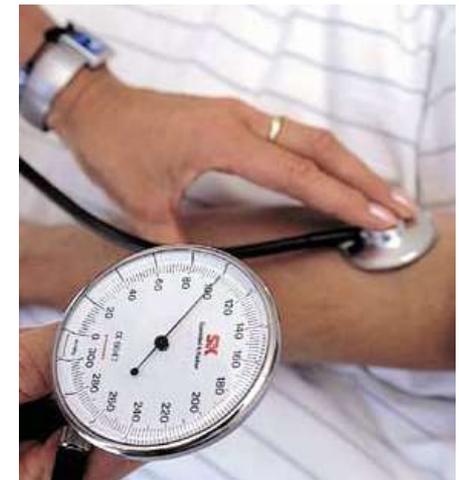
gut



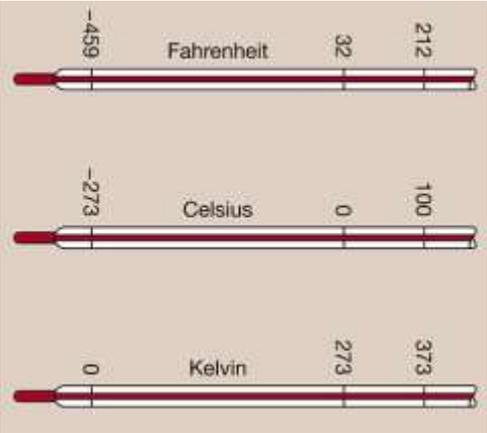
gut

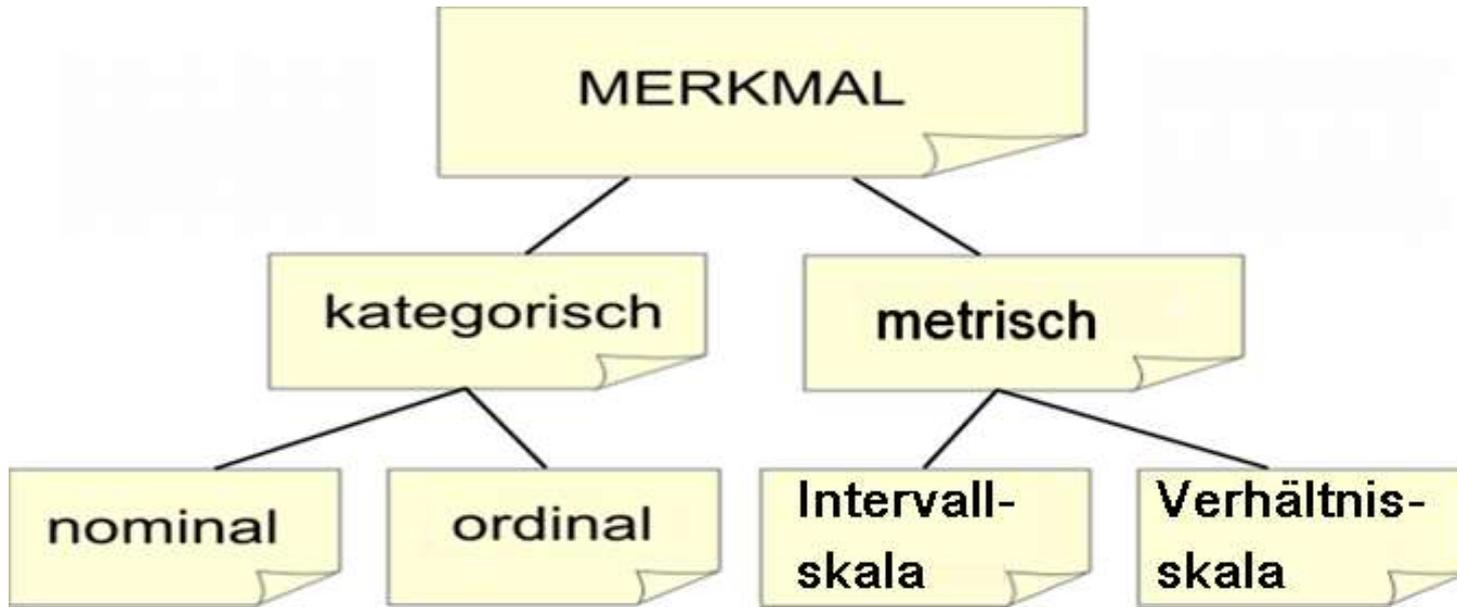
besser

am besten



# Skalentypen der metrischen Merkmale

	diskret	kontinuierlich																																																	
<p><b>Intervallskala</b></p> <p>definierte Differenz, „kein“ 0 Punkt</p>	<p>Tage in einem Kalender</p> <table border="1" data-bbox="782 396 1116 716"> <thead> <tr> <th colspan="7">Feb - 2009</th> </tr> <tr> <th>Mo</th> <th>Di</th> <th>Mi</th> <th>Do</th> <th>Fr</th> <th>Sa</th> <th>So</th> </tr> </thead> <tbody> <tr> <td>26</td> <td>27</td> <td>28</td> <td>29</td> <td>30</td> <td>31</td> <td>1</td> </tr> <tr> <td>2</td> <td>3</td> <td>4</td> <td>5</td> <td>6</td> <td>7</td> <td>8</td> </tr> <tr> <td>9</td> <td>10</td> <td>11</td> <td>12</td> <td>13</td> <td>14</td> <td>15</td> </tr> <tr> <td>16</td> <td>17</td> <td>18</td> <td>19</td> <td>20</td> <td>21</td> <td>22</td> </tr> <tr> <td>23</td> <td>24</td> <td>25</td> <td>26</td> <td>27</td> <td>28</td> <td>1</td> </tr> </tbody> </table>	Feb - 2009							Mo	Di	Mi	Do	Fr	Sa	So	26	27	28	29	30	31	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	1	<p>Temperatur in °C</p> 
Feb - 2009																																																			
Mo	Di	Mi	Do	Fr	Sa	So																																													
26	27	28	29	30	31	1																																													
2	3	4	5	6	7	8																																													
9	10	11	12	13	14	15																																													
16	17	18	19	20	21	22																																													
23	24	25	26	27	28	1																																													
<p><b>Verhältnisskala</b></p> <p>definiertes Verhältnis, 0 Punkt</p>	<p>Anzahl der Zähne</p> 	<p>Temperatur in K</p> 																																																	



$=, \neq$

$=, \neq$

$=, \neq$

$=, \neq$

**Auseinanderhalten**

$<, >$

$<, >$

$<, >$

**Anordnung**

$+, -$

$+, -$

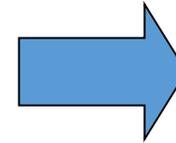
**Differenz**

$*, /$

**Verhältnis** <sup>14</sup>

„Entwicklungsstand“





Ein  
Element

**Stichprobe:**

**Grundgesamtheit (Population):**

Gesamtheit der Individuen (Elemente),  
deren Eigenschaften bei der Studie  
untersucht werden sollen.

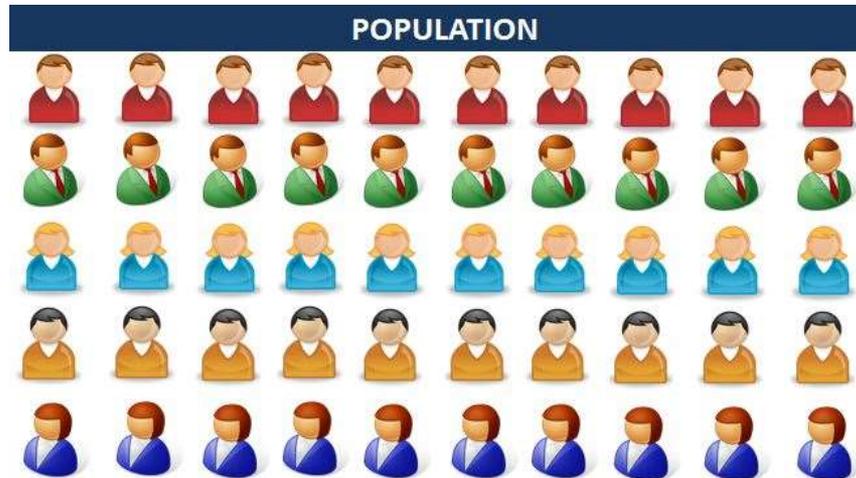
$N = \infty$  oder ungeheuer groß

Der für die Studie  
ausgewählte Teil der  
Population.

$n \ll N$

*Umfang d. Stichprobe =  
Anzahl d. Daten*

Wir brauchen eine **repräsentative Stichprobe**



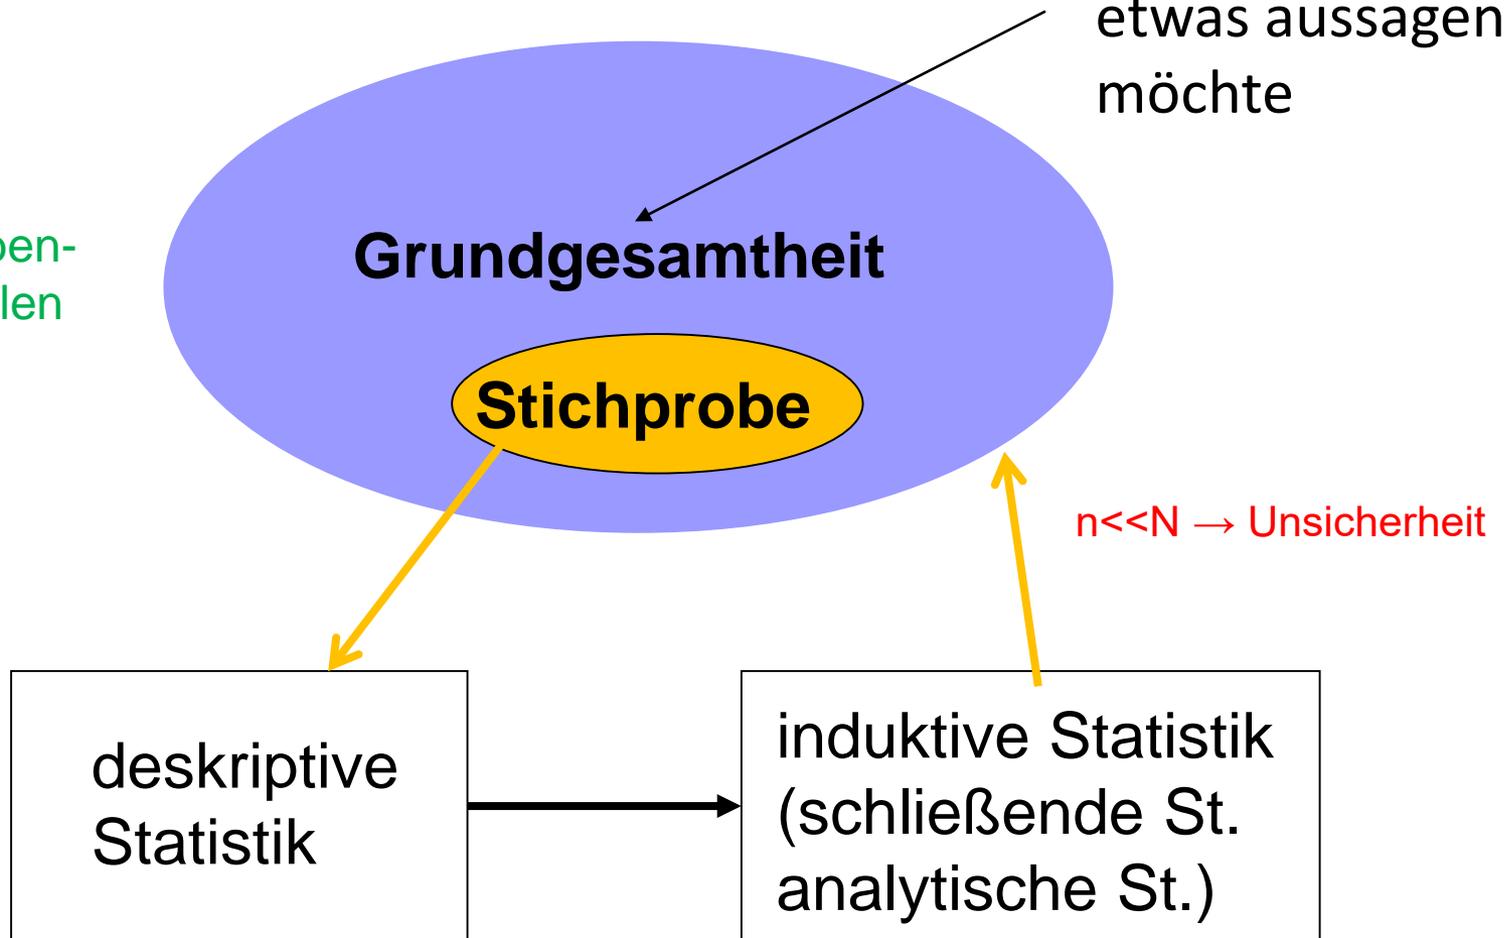
Gut, repräsentativ



Nicht gut!  
ganz andere Zusammensetzung als die der Population

die Stichproben-  
elemente sollen  
zufällig  
ausgewählt  
werden

über die man  
etwas aussagen  
möchte



Frage: Wie hoch ist die normale Pulsfrequenz?

Merkmal: Pulsfrequenz (1/Min), metrisch mit Verhältnisskala



## Stichprobe

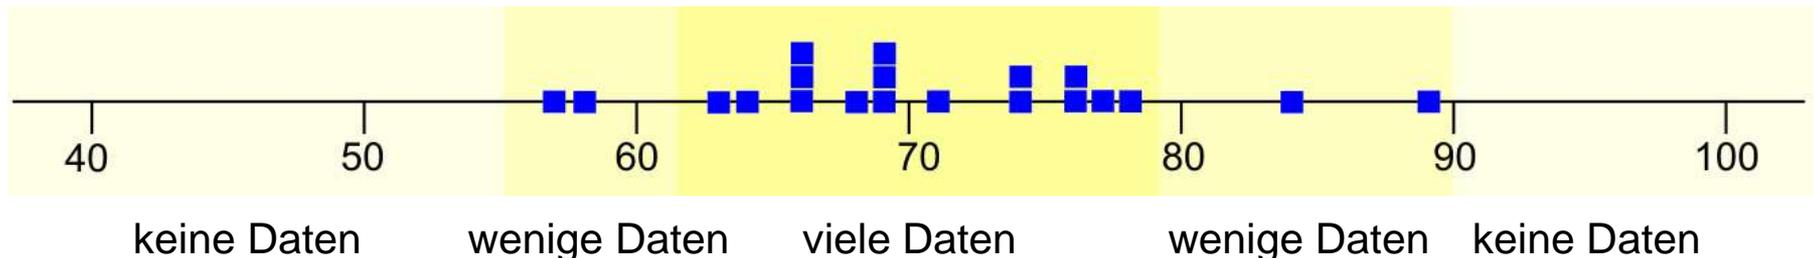
66	56	89	63	66	69	71	68	58	69
78	66	64	84	74	76	69	77	74	76

Was kann man damit anfangen? (wären z.B. 700 Daten....)



Die Werte sollen **geordnet** und **verdichtet** werden.

Stellen wir die Daten entlang einer Zahlengeraden dar!



# benutzen wir Klassen!

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

Die Klassengrenzen sind nach Belieben festlegbar.

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:	$n = 20$

Excel:

=frequency(...)

=Häufigkeit(...)

Hier z.B. Die Klassenbreite ist 5, Grenzen sind zu Zehner angepasst.

# Häufigkeitsdichte

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

Einheit:  $\left( \frac{\frac{\text{Stück}}{5 \frac{1}{\text{Min}}}}{\frac{\text{St.} \cdot \text{Min}}{5}} \right)$

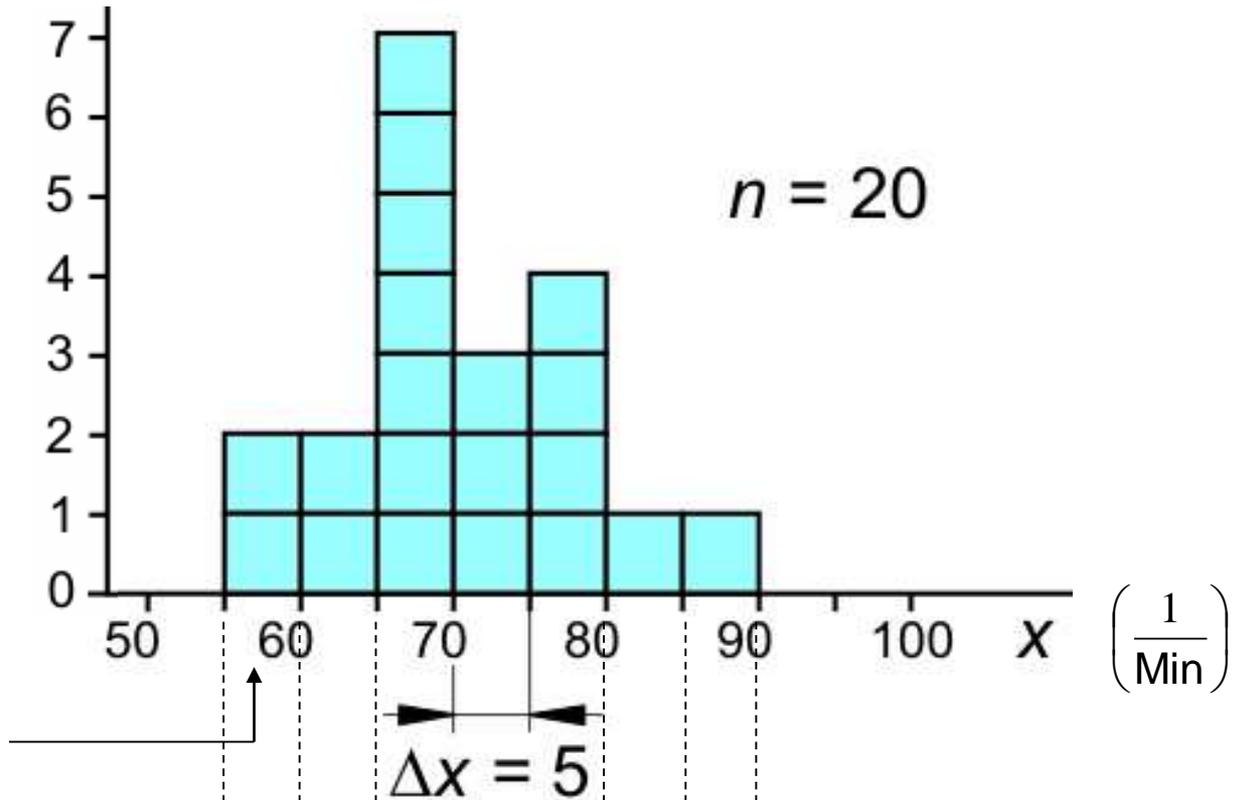
n.B. „Stück“ als Einheit lässt man oft weg.

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

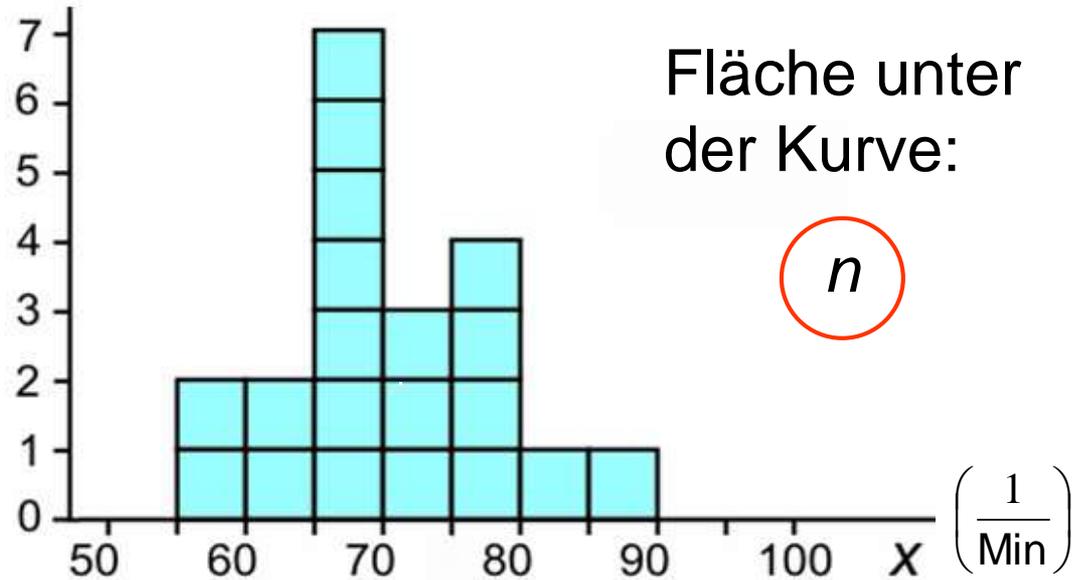


KLASSENRENZEN	HÄUFIGKEIT
$55 \leq x_i < 60$	2
$60 \leq x_i < 65$	2
$65 \leq x_i < 70$	7
$70 \leq x_i < 75$	3
$75 \leq x_i < 80$	4
$80 \leq x_i < 85$	1
$85 \leq x_i < 90$	1
<b>insgesamt:</b>	<b><math>n = 20</math></b>

# Häufigkeitsdichte- verteilung

**absolute**

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

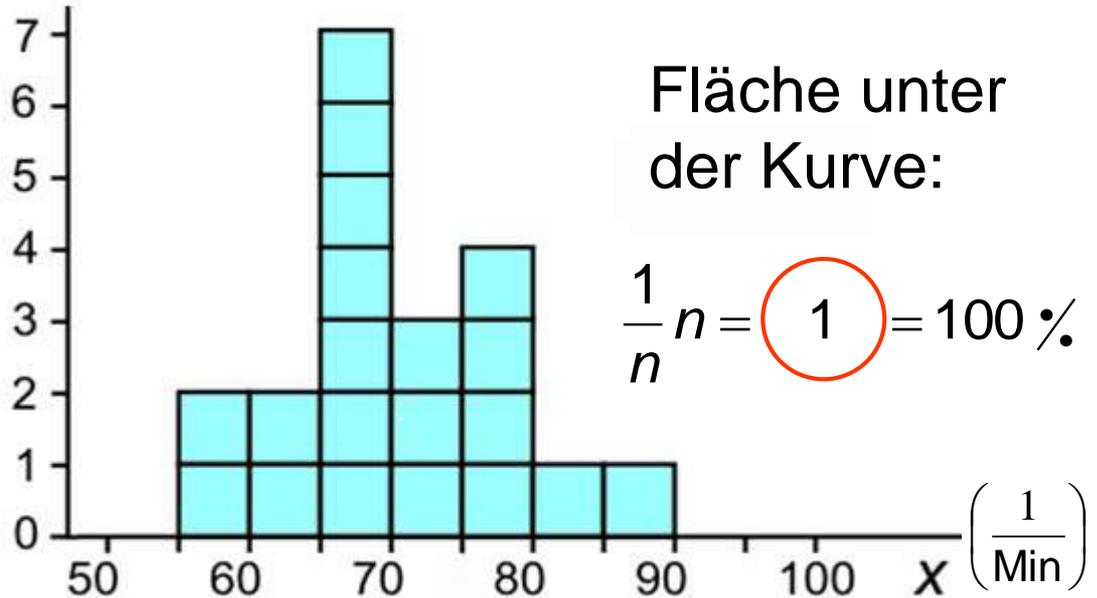


Fläche unter  
der Kurve:

$$n$$

**relative**

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



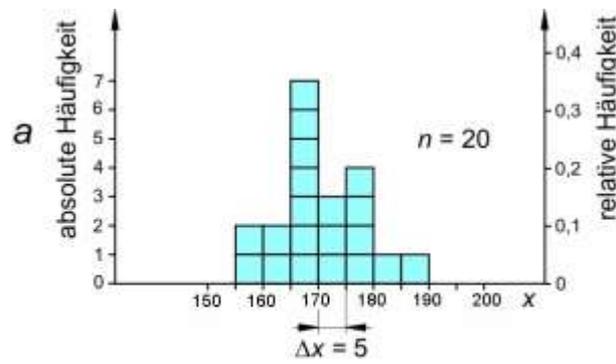
Fläche unter  
der Kurve:

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

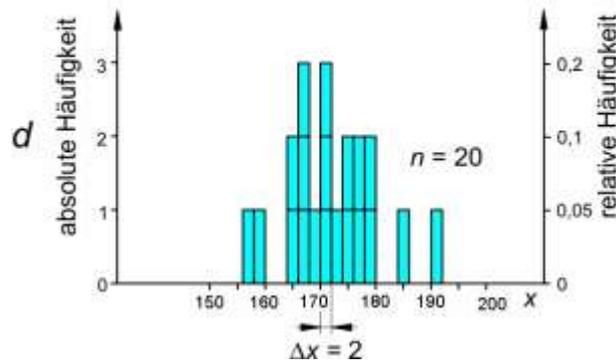
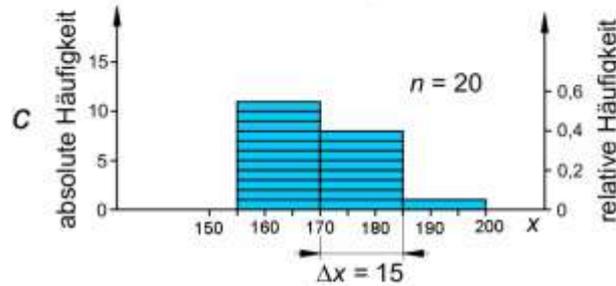
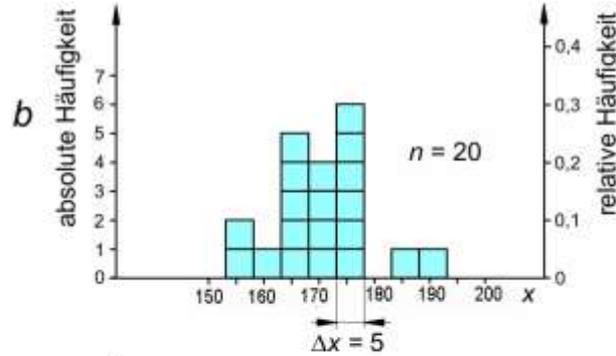
Die Klassenbreite kann das Aussehen des Histogramms wesentlich beeinflussen, wenn die Datenmenge nicht groß genug ist.  
 In diesem Fall gibt es auch eine relativ hohe Instabilität des Histogramms

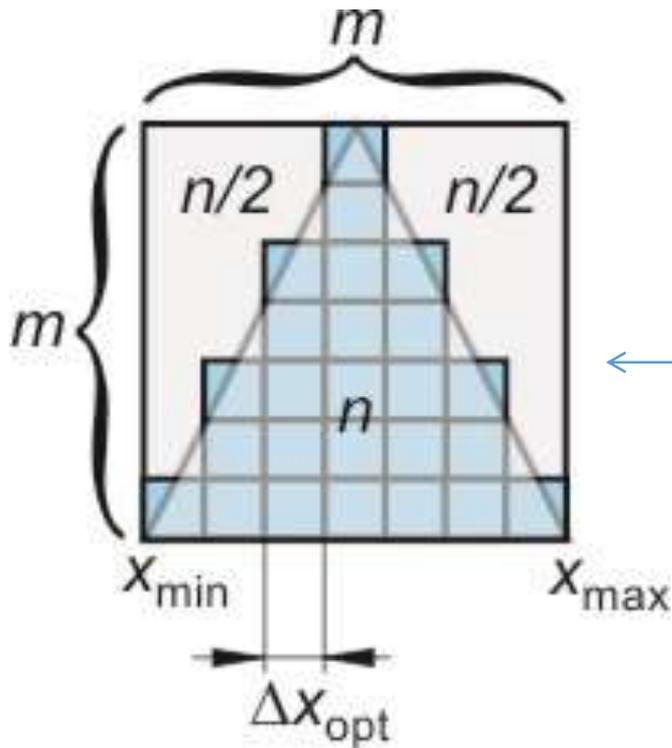
Zu große Klassenbreite

Zu kleine Klassenbreite



Selbe Grundgesamtheit, 2 Stchproben





## Bestimmung der optimalen Klasseneinteilung

Weil oft die Daten um einem zentralen Wert gestreut sind, hat das Histogramm ein „Gipfel“.

optimale Klassenanzahl  $m$  Stück:

$$m^2 = 2n$$

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

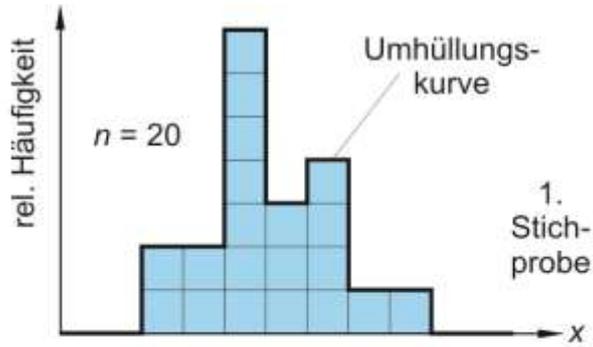
$$m = \sqrt{40} = 6.3$$

optimale Klassenbreite  $\Delta x$ :

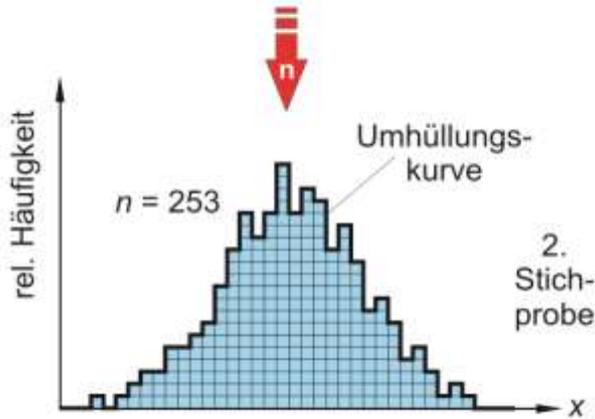
$$\Delta x = \frac{x_{\max} - x_{\min}}{m}$$

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

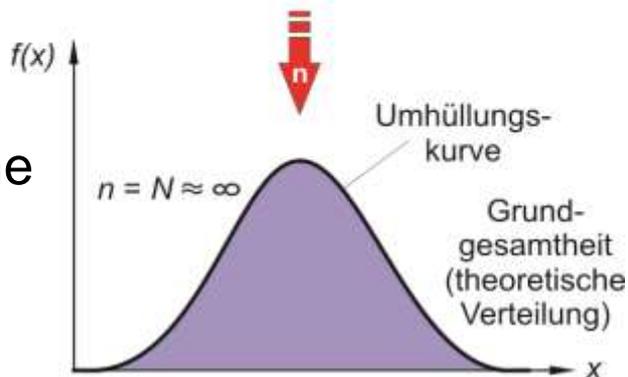
empirische  
Funktion



empirische  
Funktion



theoretische  
Funktion

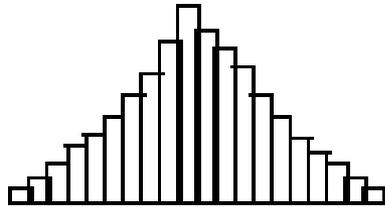


$n$  vergrößert sich,  
die Klassenbreite  $\Delta x$  kann  
verkleinert werden

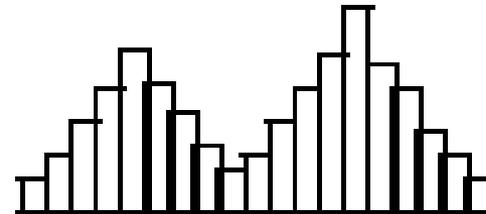
**Bei großen Stichproben** ergibt die empirische Verteilungsfunktion **eine sehr gute Näherung** der theoretischen Verteilungsfunktion. (Die Stichprobe ist „fast gleich“ der Grundgesamtheit.)

# Analyse von Häufigkeitsverteilungen

homogene symmetrische Stichprobe:



heterogene Stichprobe:

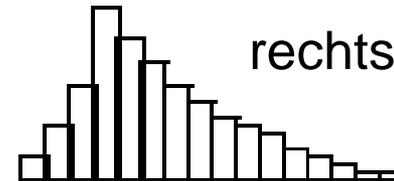


homogene nichtsymmetrische Stichproben:

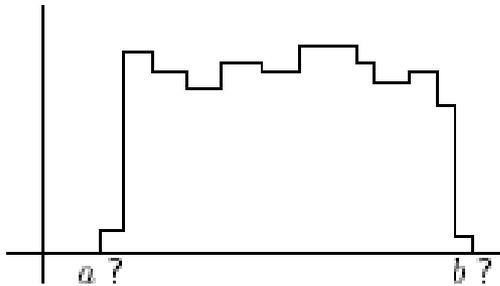
linksschief



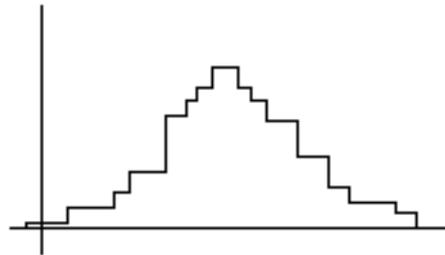
rechtsschief



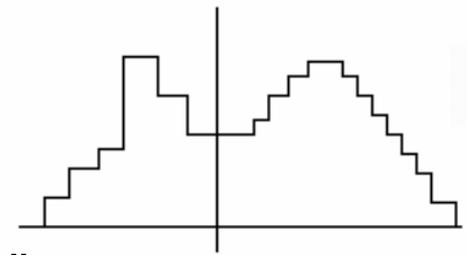
Vermutungen macht man auch:



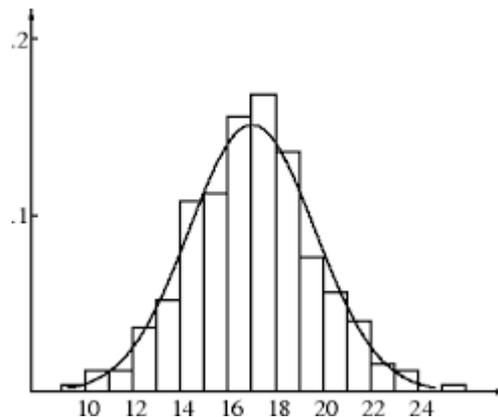
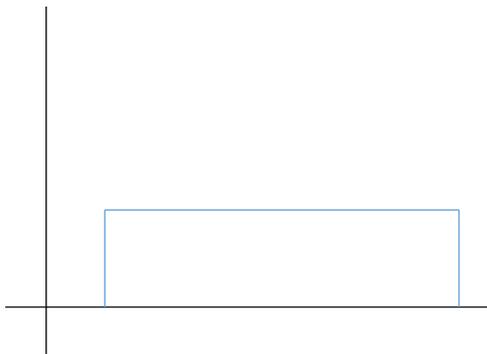
Gleichverteilung?



Normalverteilung?



Überlagerung von zwei Normalverteilungen?

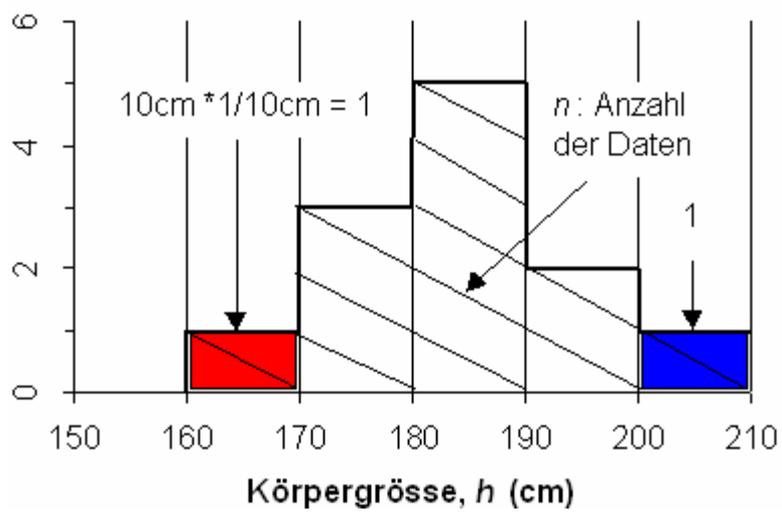


Vergleichen mit bekannten Verteilungen...

# Häufigkeitsverteilung

$$\frac{\Delta N}{\Delta h}$$

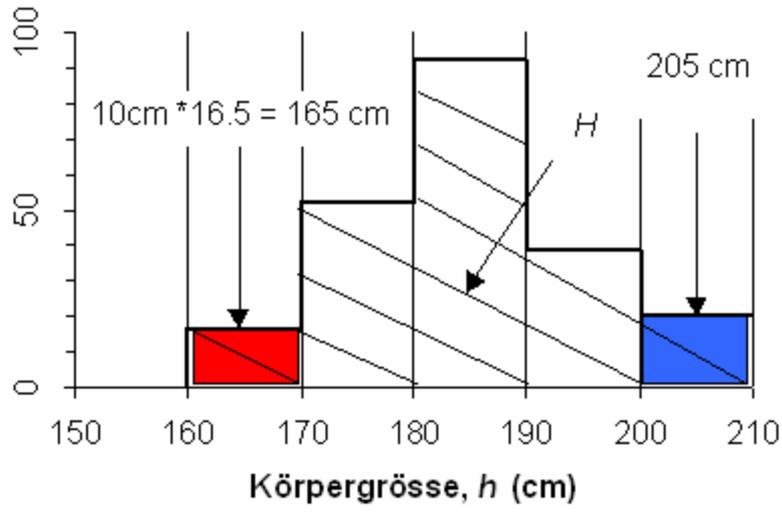
$$\left( \frac{1}{10\text{cm}} \right)$$



$h$ : Körperhöhe

$H$ : kollektive Höhe, Gesamthöhe

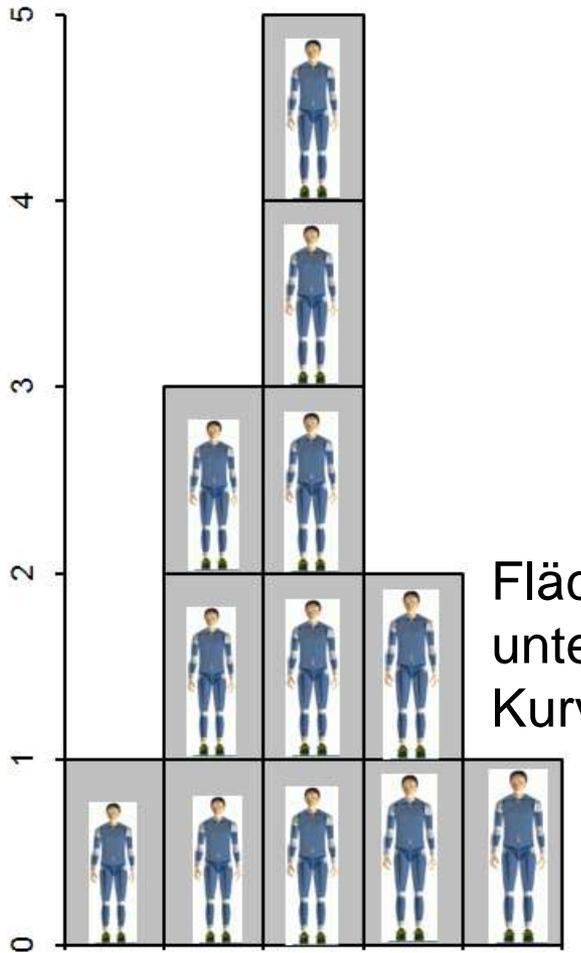
$$\frac{\Delta H}{\Delta h}$$



**Spektrum** ist eine spezielle Häufigkeitsverteilung

# Häufigkeitsdichte

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



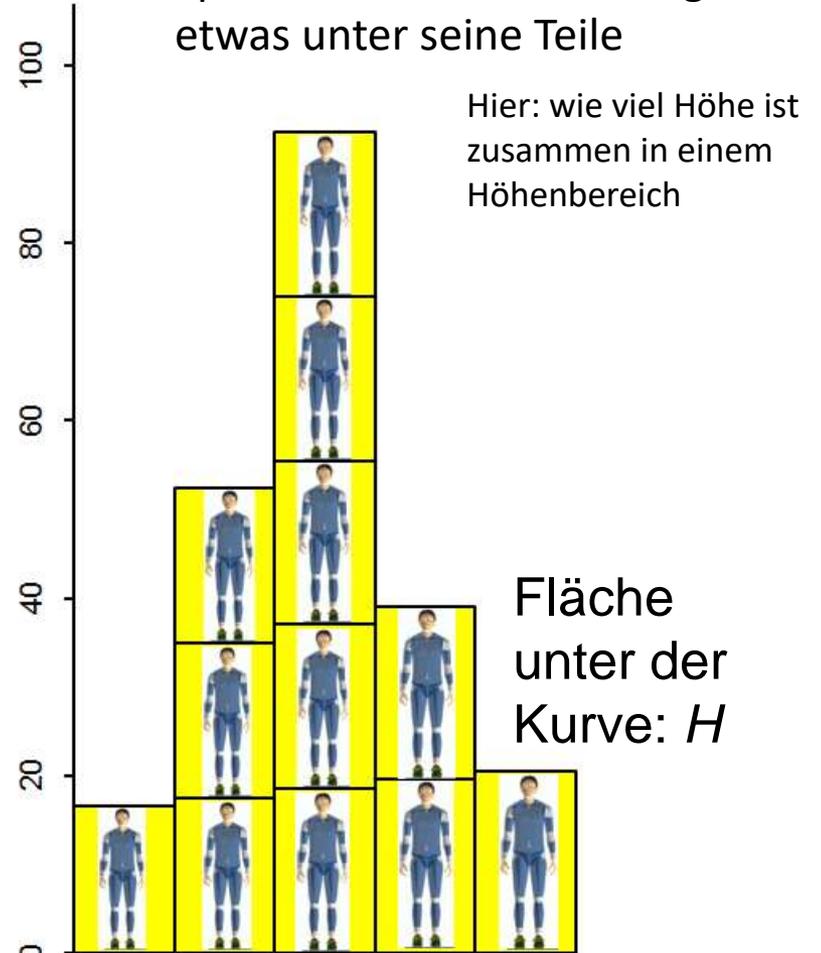
160 170 180 190 200 210

$h$  (cm)

# Spektrum

Spektrum ist die Verteilung von etwas unter seine Teile

$$\frac{\Delta H}{\Delta h}$$



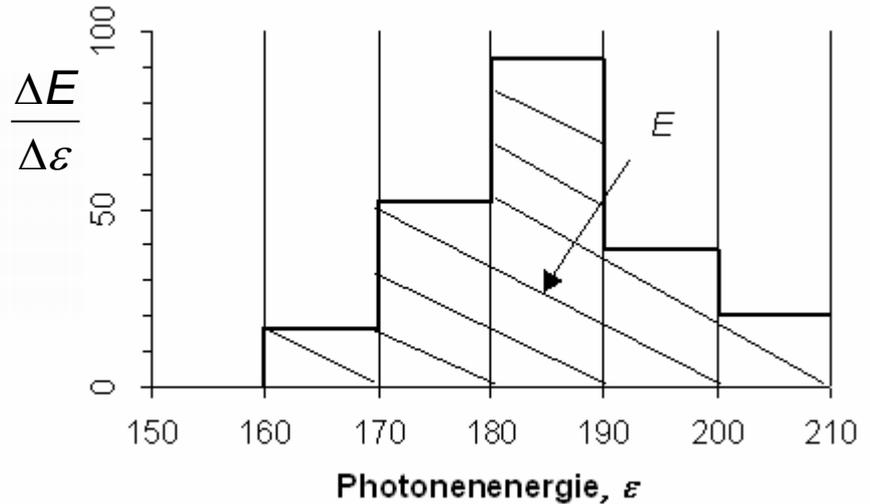
160 170 180 190 200 210

$h$  (cm)

# Beispiel aus der Physik

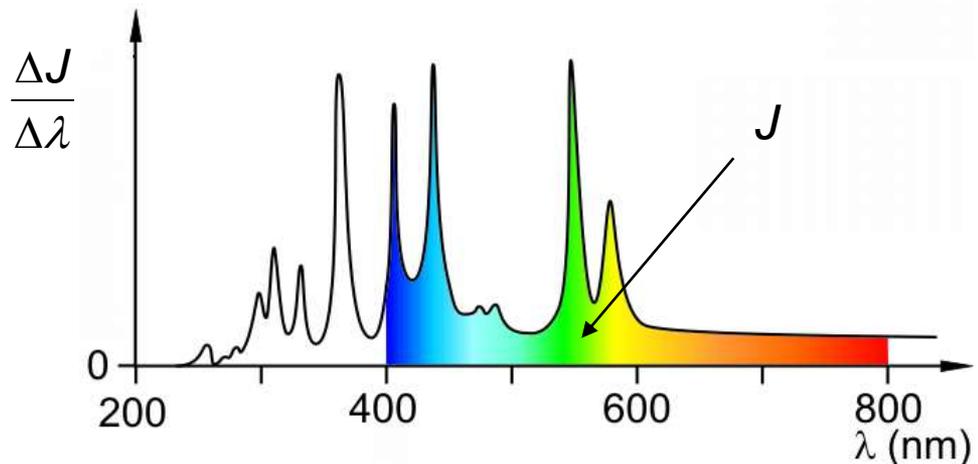
## Emissionsspektrum:

wie verteilt sich die emittierte Energie über die Photonenenergien



charakteristische Größe des Energietransports:  
**Intensität**

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



# 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)

Beispiel: Schritte

$$x_1 + x_2 + x_3 =$$



$$= \bar{x} + \bar{x} + \bar{x} = 3\bar{x}$$

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

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

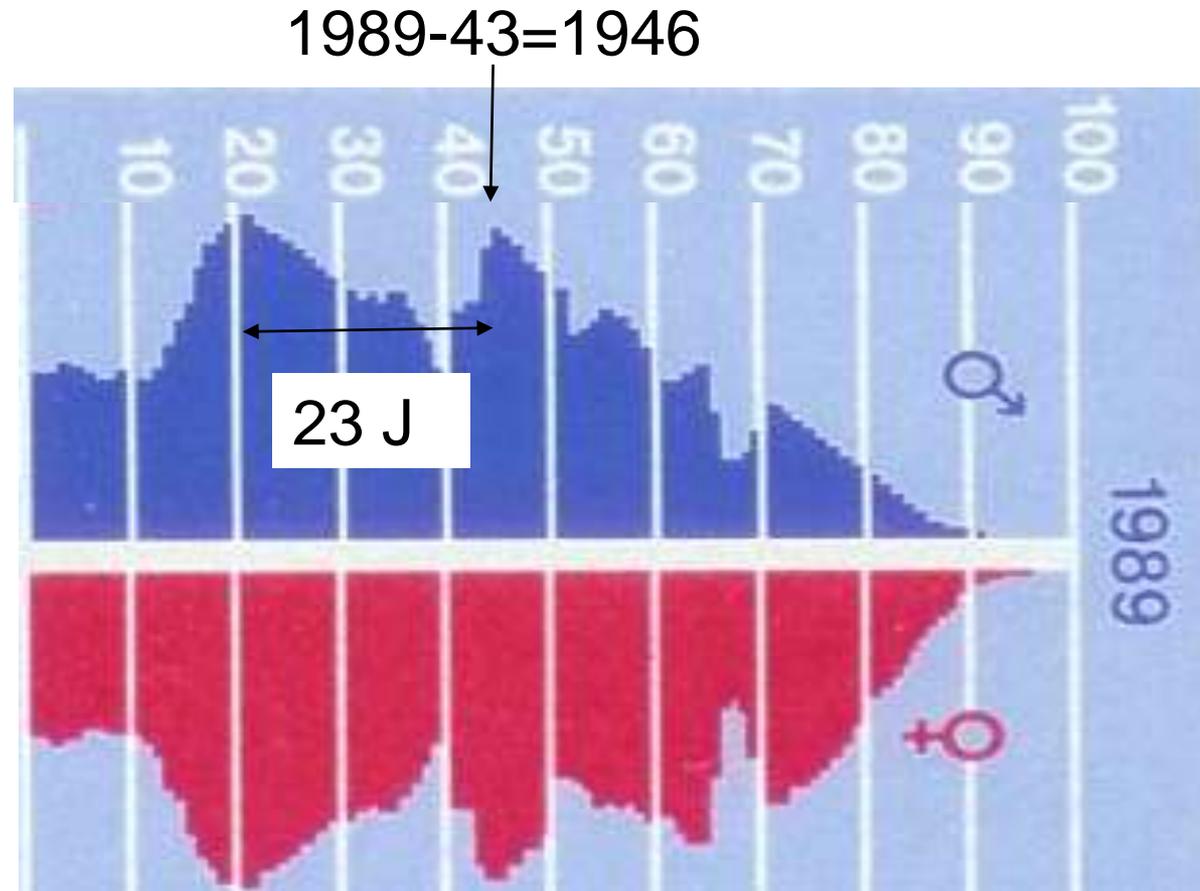
$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}$$

=Mittelwert(...)

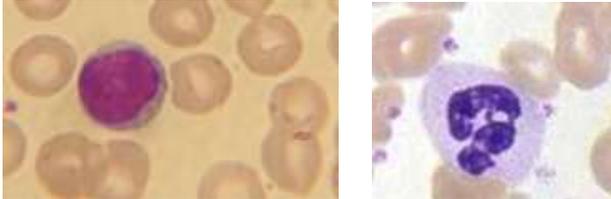
## Beispiel, und modalität

### Altersaufbau der deutschen Bevölkerung

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

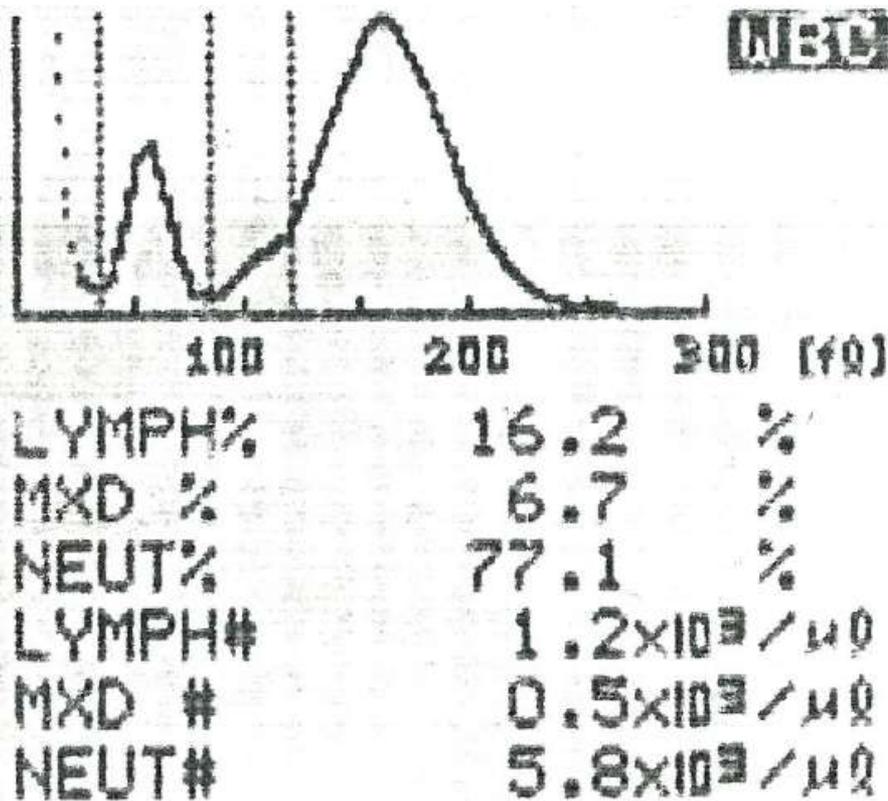


## Beispiel in der Medizin

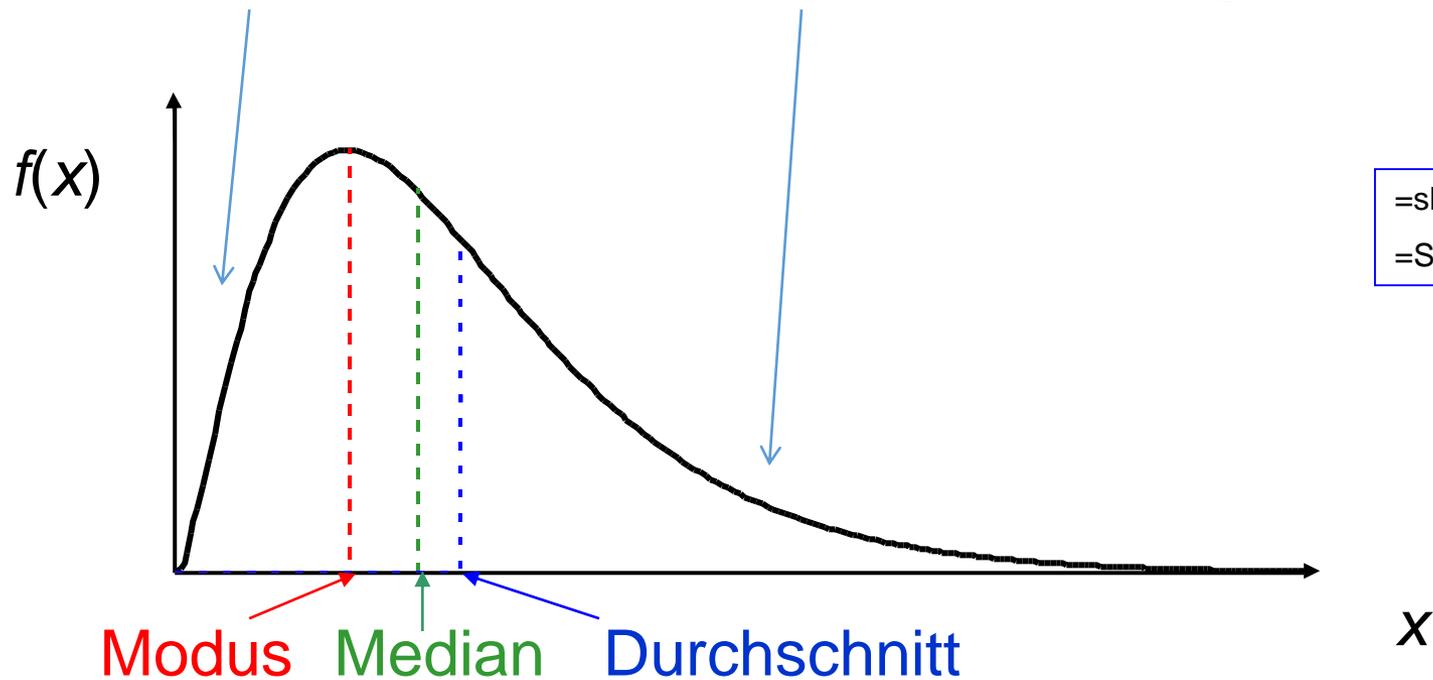


# Coulter Zähler

Größenverteilung der Zellen



## Linkssteile bzw. **rechtsschiefe** Verteilung

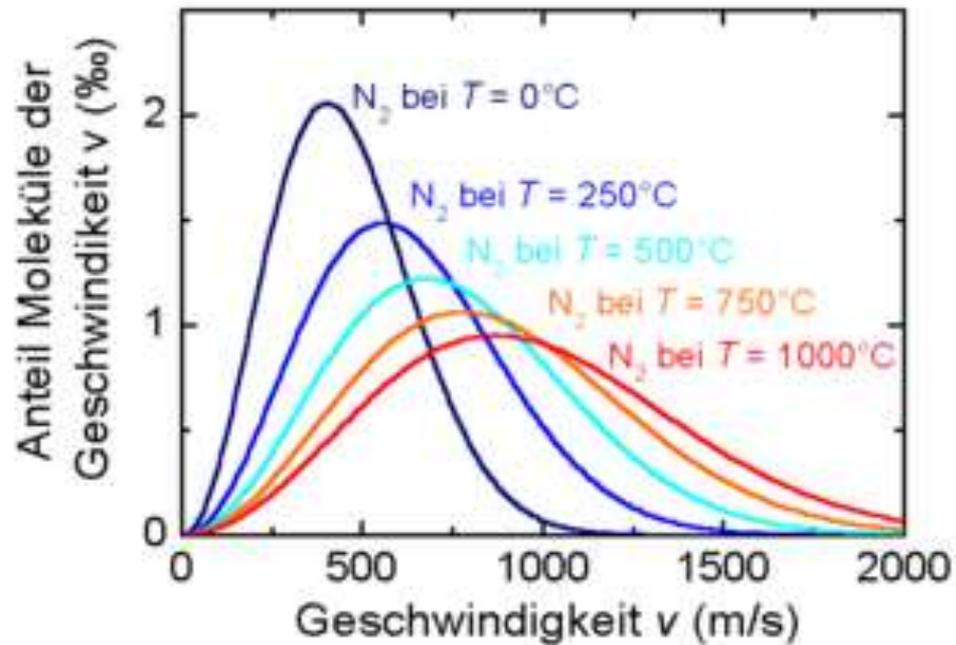


z.B. Einkommensverteilungen in einem Land:

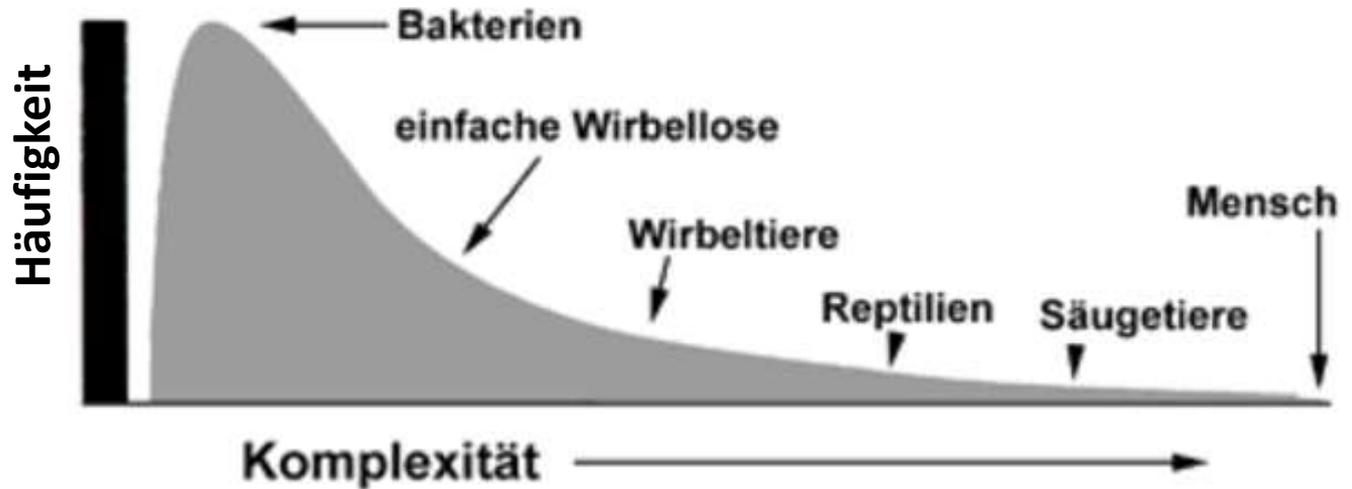
Der Großteil der Bevölkerung verdient relativ wenig, während es nur wenig Leute gibt, die sehr viel verdienen.

# Weitere Beispiele

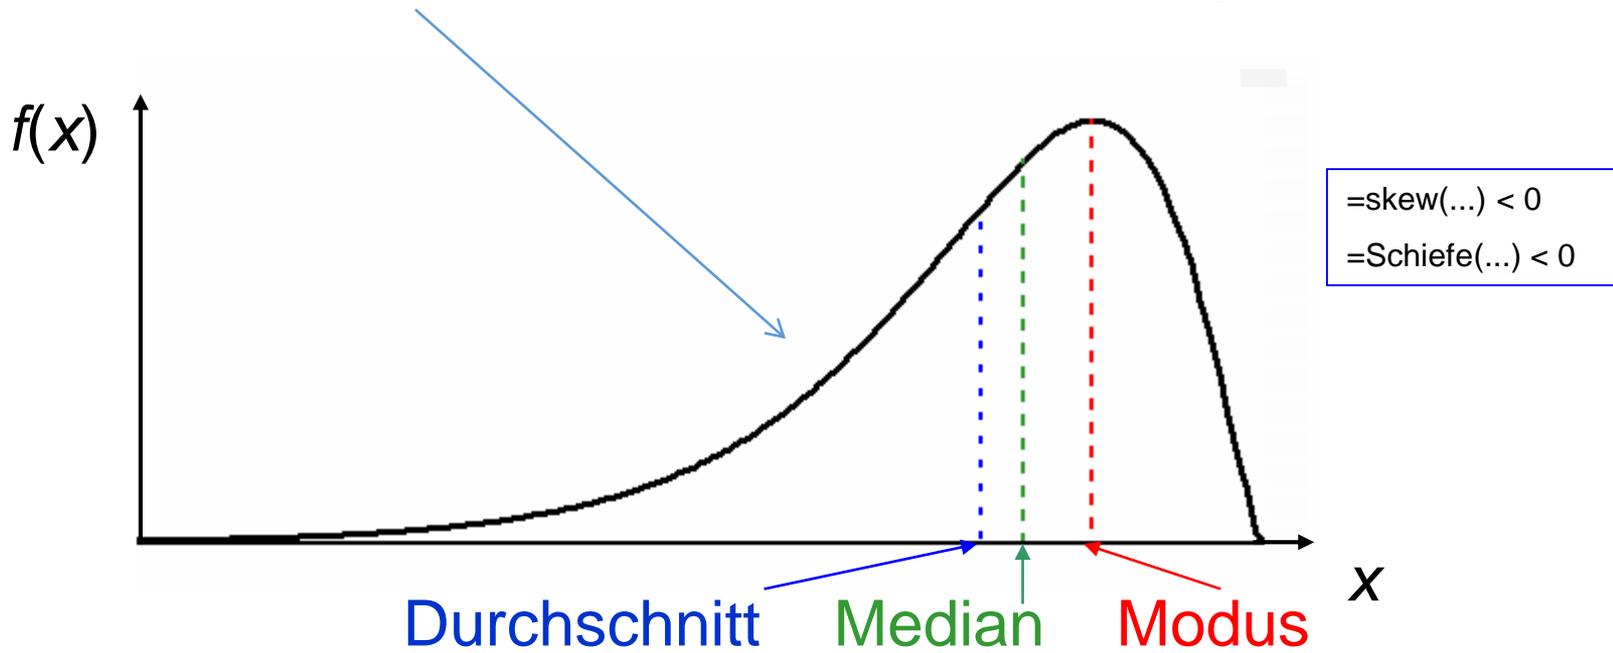
Maxwell-Boltzmann-Verteilung  
(siehe später in der Physik)



Komplexität der Tiere



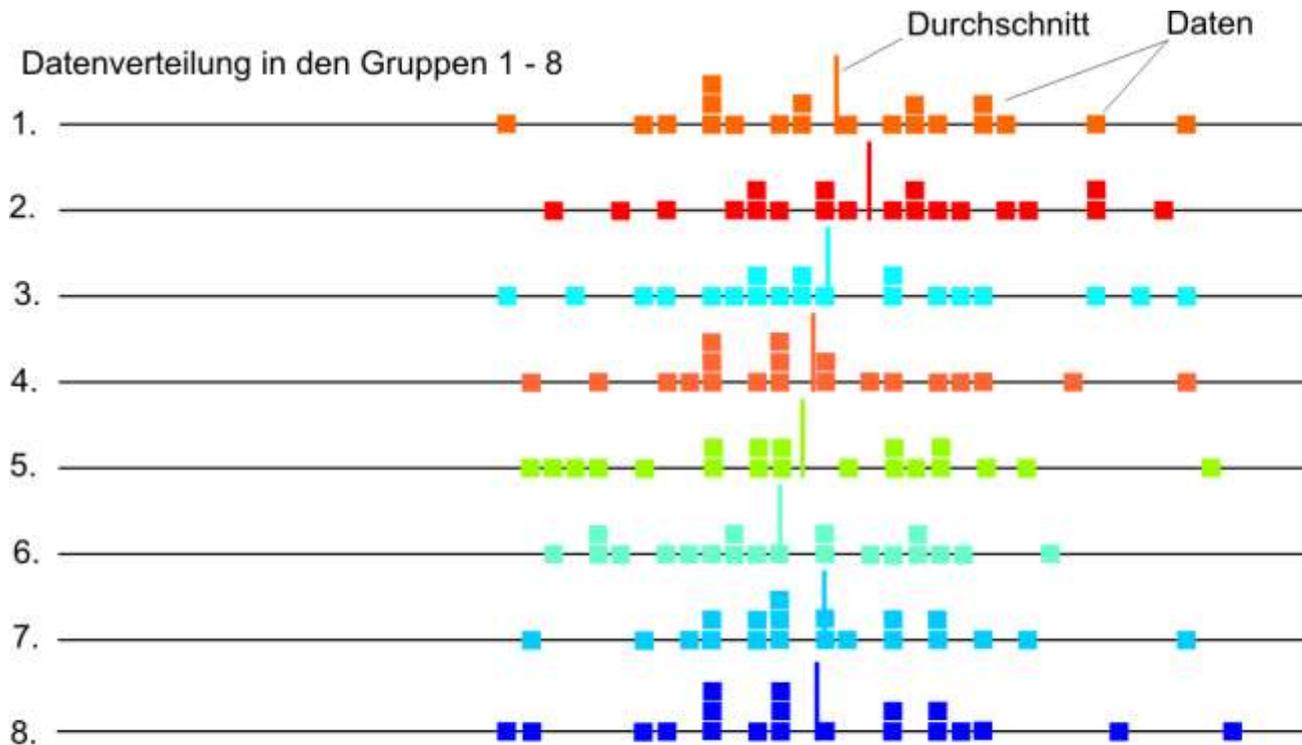
# Linksschiefe bzw. rechtssteile Verteilung



z.B. Dauer einer Schwangerschaft

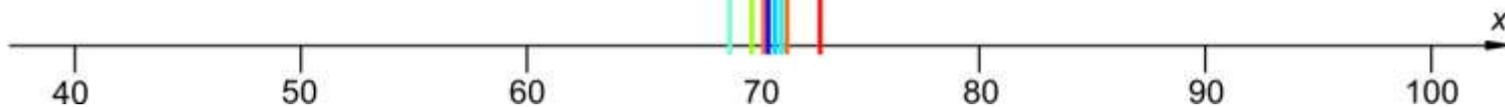


# Daten und ihre Durchschnittswerte



Die Daten streuen um den Durchschnittswert.

Verteilung der Durchschnittswerte der Gruppen 1 - 8



Pulsfrequenzen (1/Min) 37

# 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(...)

# $\alpha$ -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(...)



Hier kann nur  
 $\alpha$  = einige  
quartile sein!

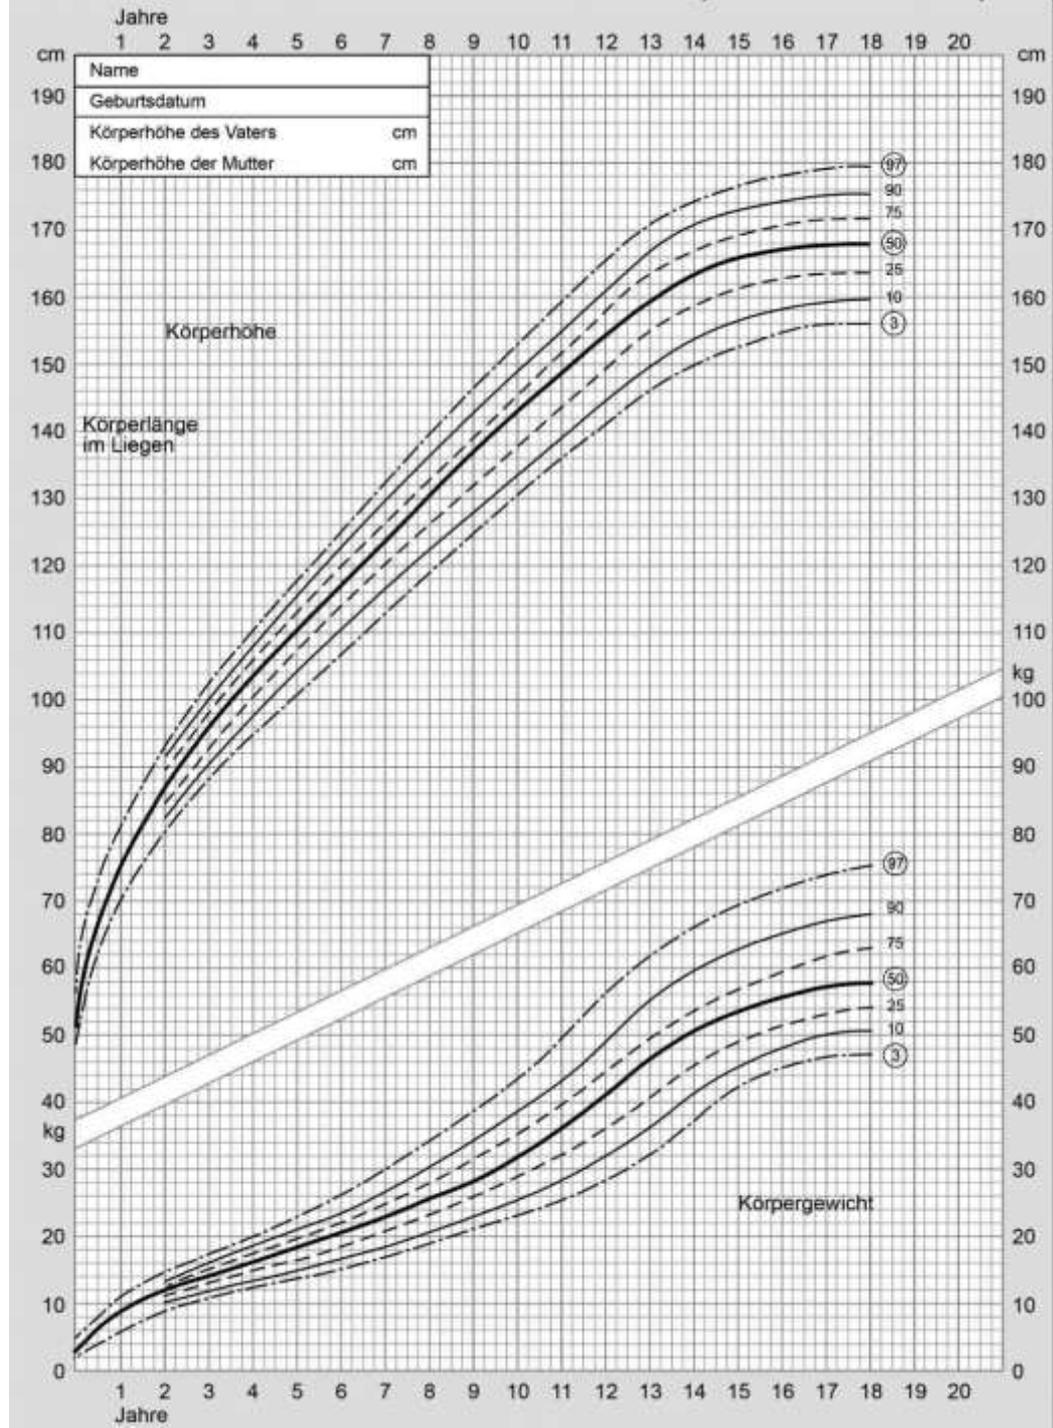
mit Wörter: z.B. **Dezile**

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

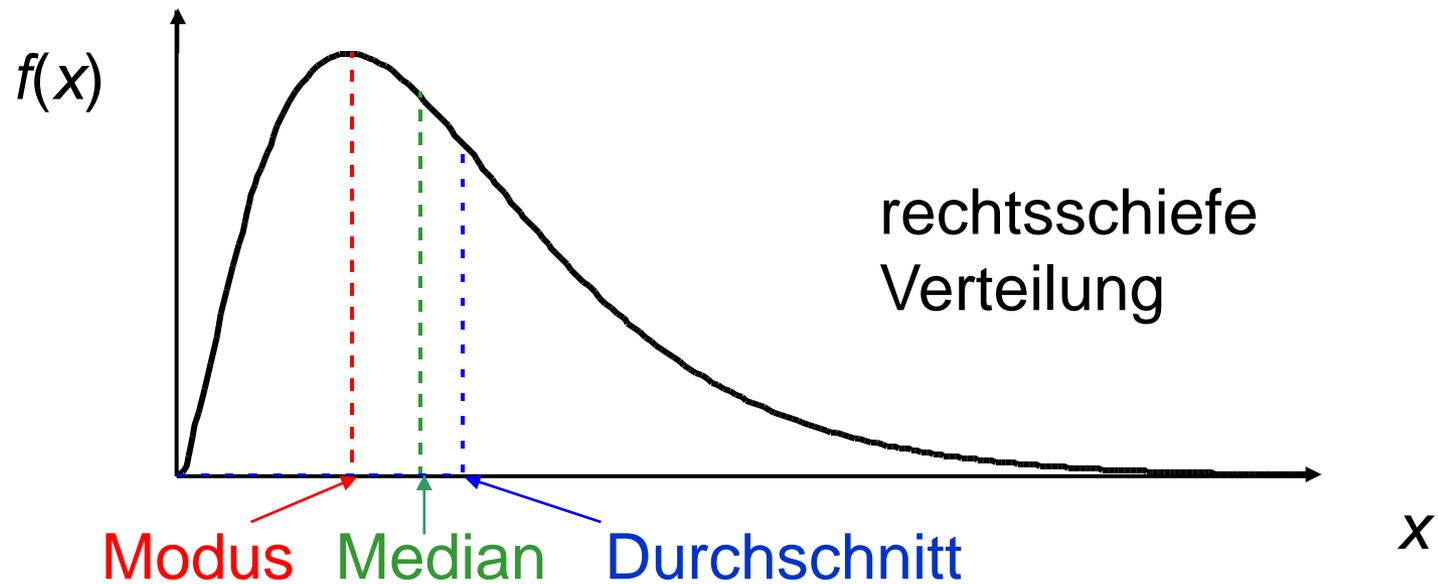
Perzentilenkurven sind ein Werkzeug für den Arzt.

Wachstums- und Gewichtskurven für Mädchen

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



Die Lageparametern sind generell nicht identisch.

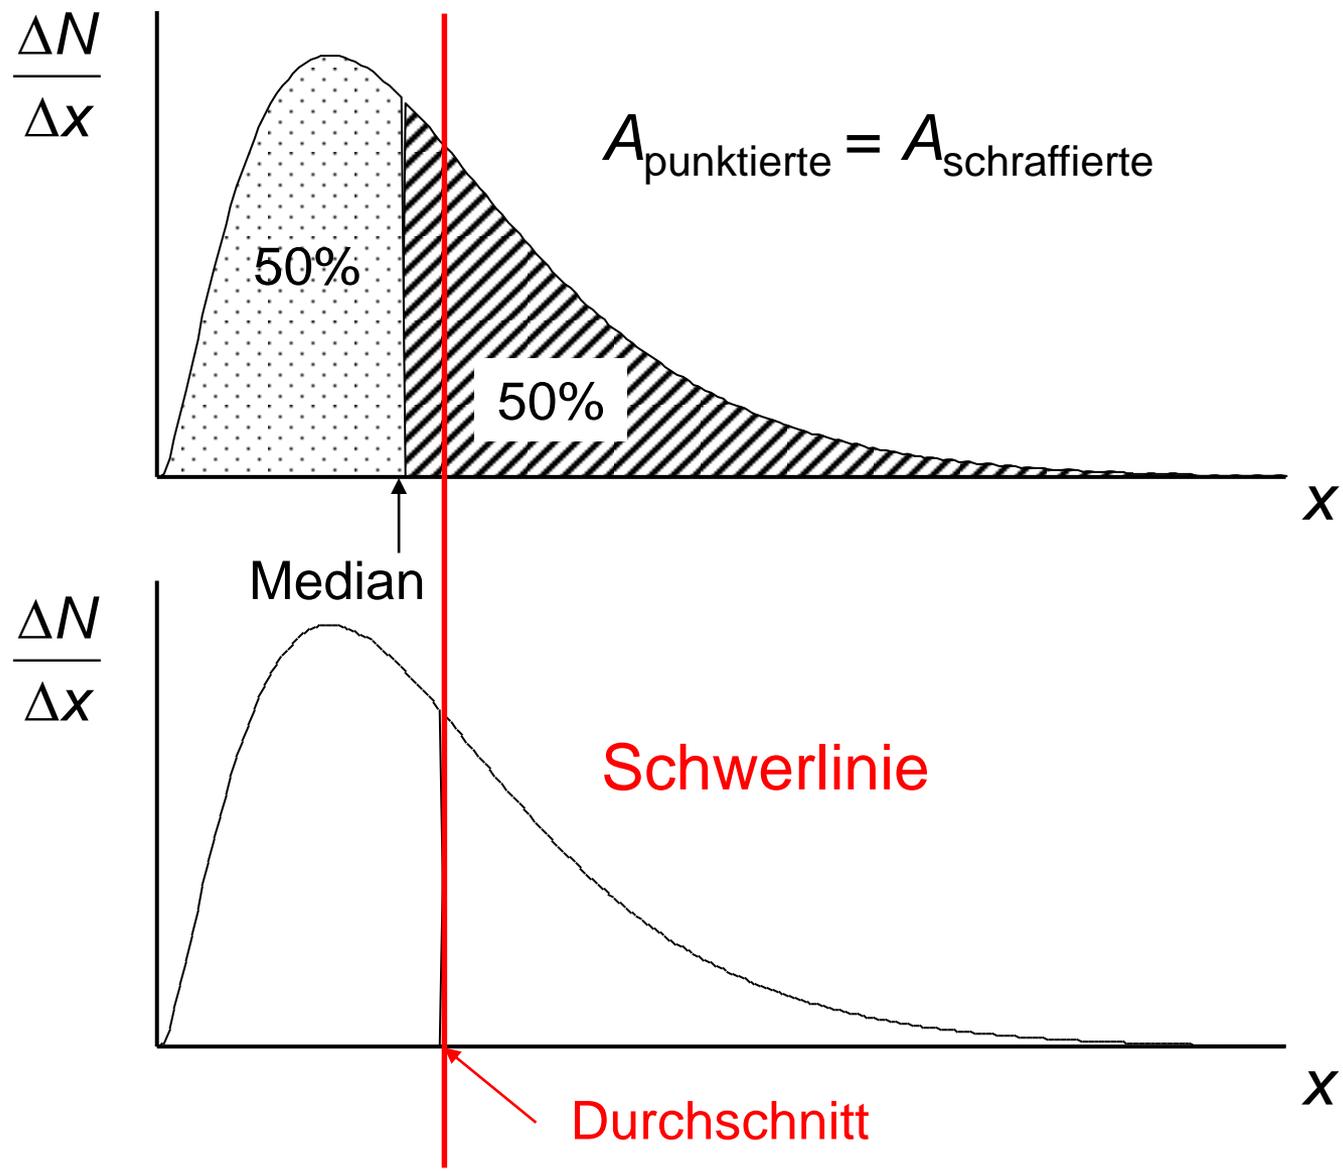


Vorsicht mit Skalentypen!

Besonders mit zahlen: die originelle Skala kann gut „nur“ nominal, oder ordinal sein (z.B. Noten)

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

# Position des Medians und des Durchschnitts einer Verteilung (1)



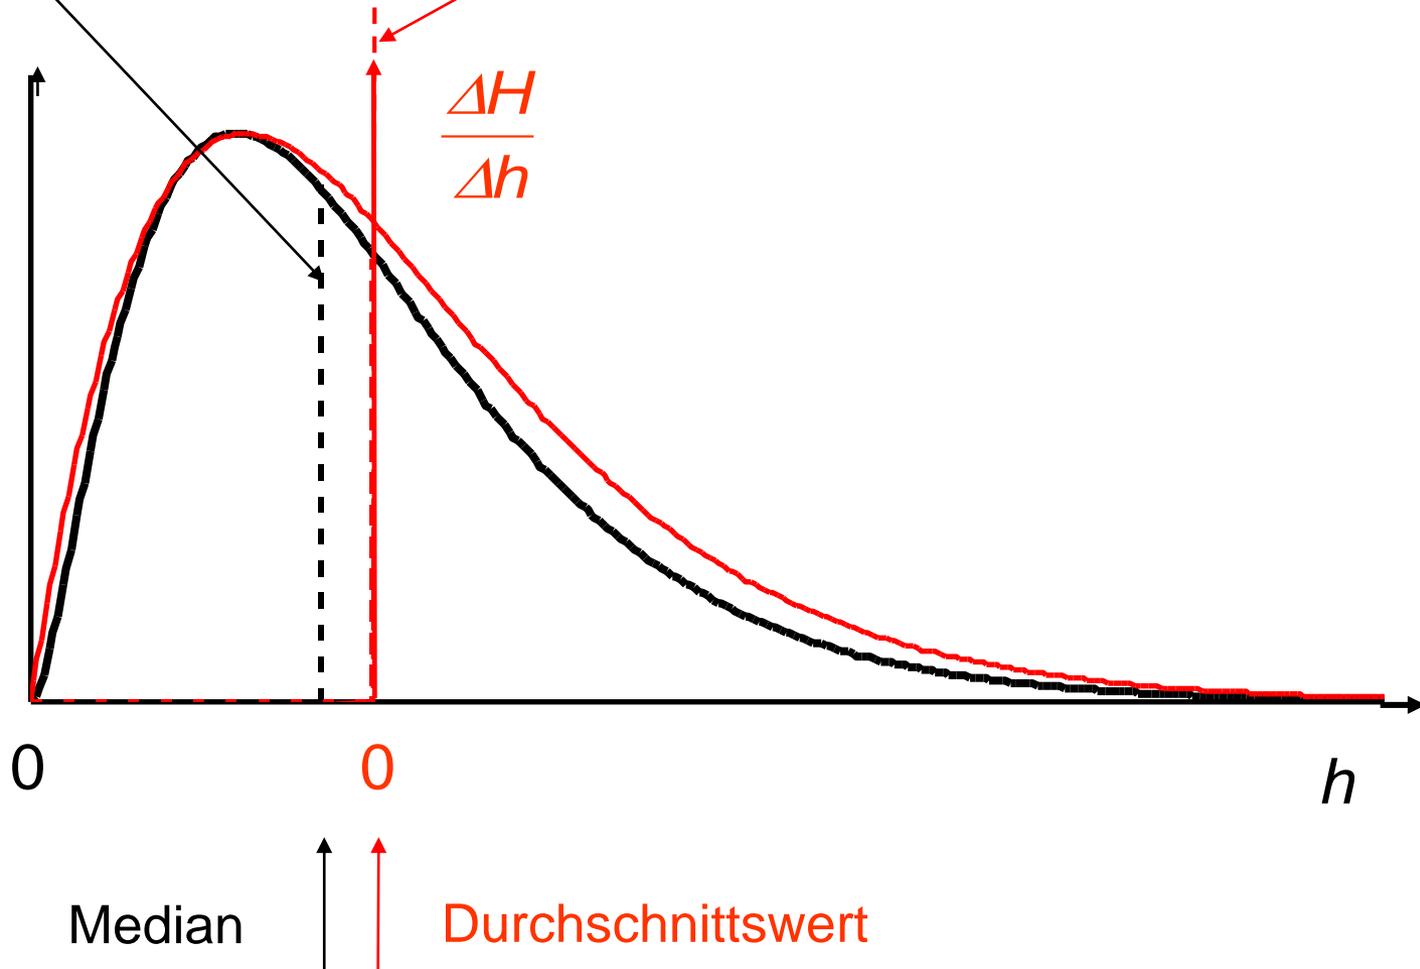
## Position des Medians und des Durchschnitts einer Verteilung (2)

Flächenhalbierungslinie  
der Häufigkeitsverteilung

Flächenhalbierungslinie  
des Spektrums

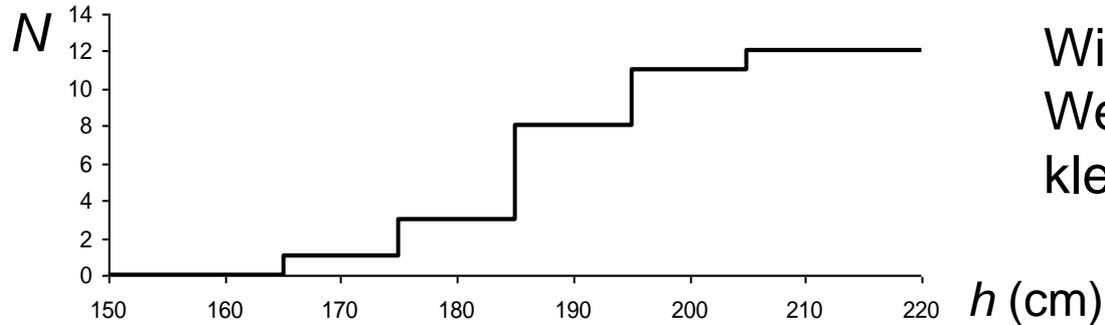
$$\frac{\Delta N}{\Delta h}$$

$$\frac{\Delta H}{\Delta h}$$



# Summen- (kumulierte/kumulative) Häufigkeitsverteilung

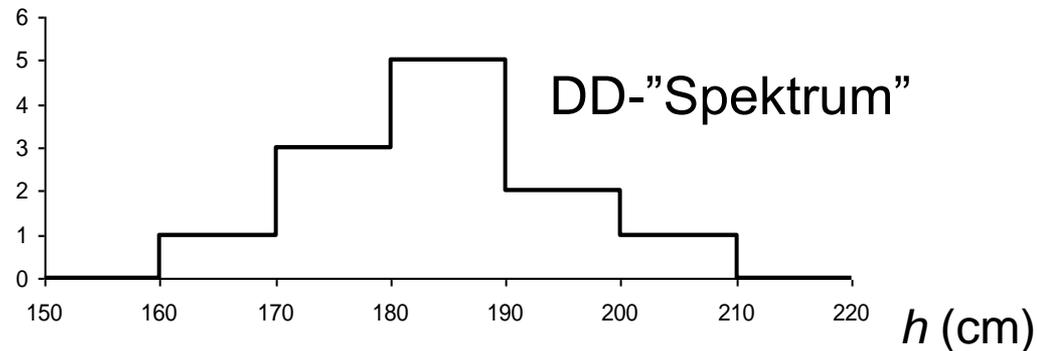
Summen-  
Häufigkeits-  
verteilung



Wieviele  
Werte sind  
kleiner als  $h$ ?

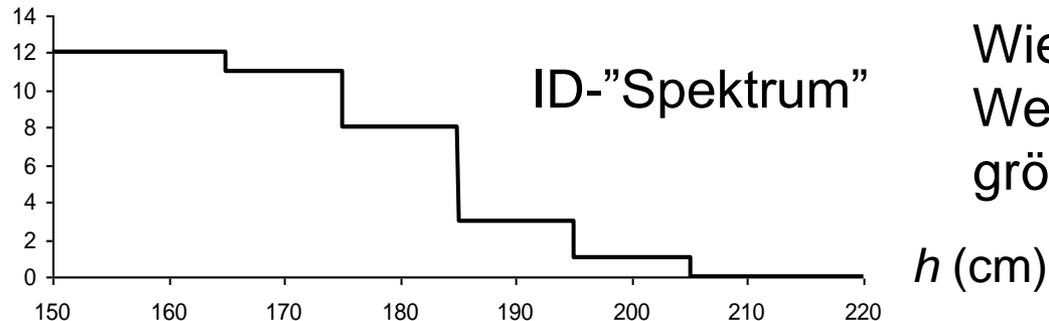
Häufigkeitsdichte-  
Verteilung

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



„Summen-  
Häufigkeits-  
verteilung“

$$M = N_0 - N$$



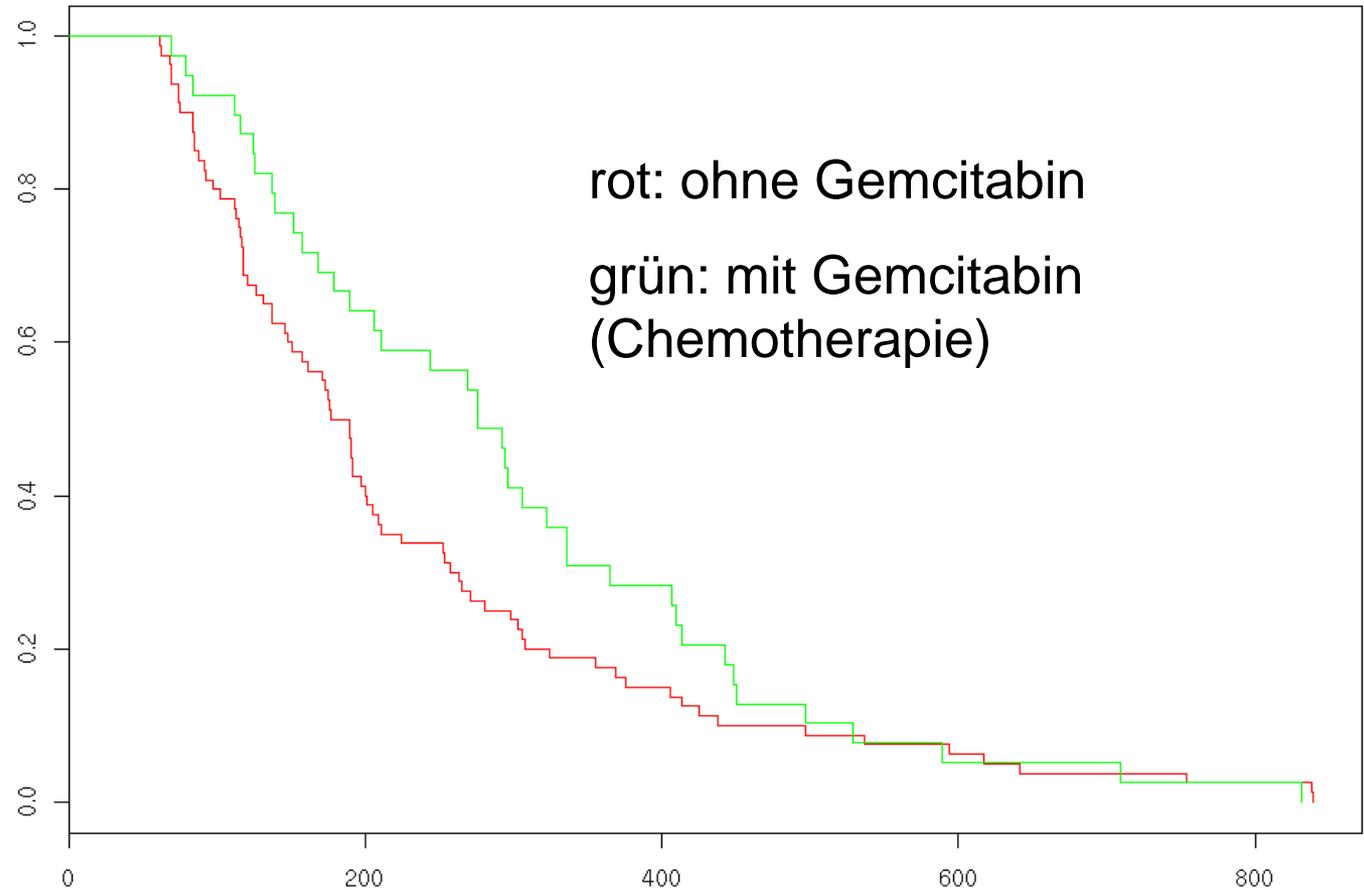
Wieviele  
Werte sind  
grösser als  $h$ ?

relative  
„Summen-  
Häufigkeits-  
verteilung“

# Überlebenskurven

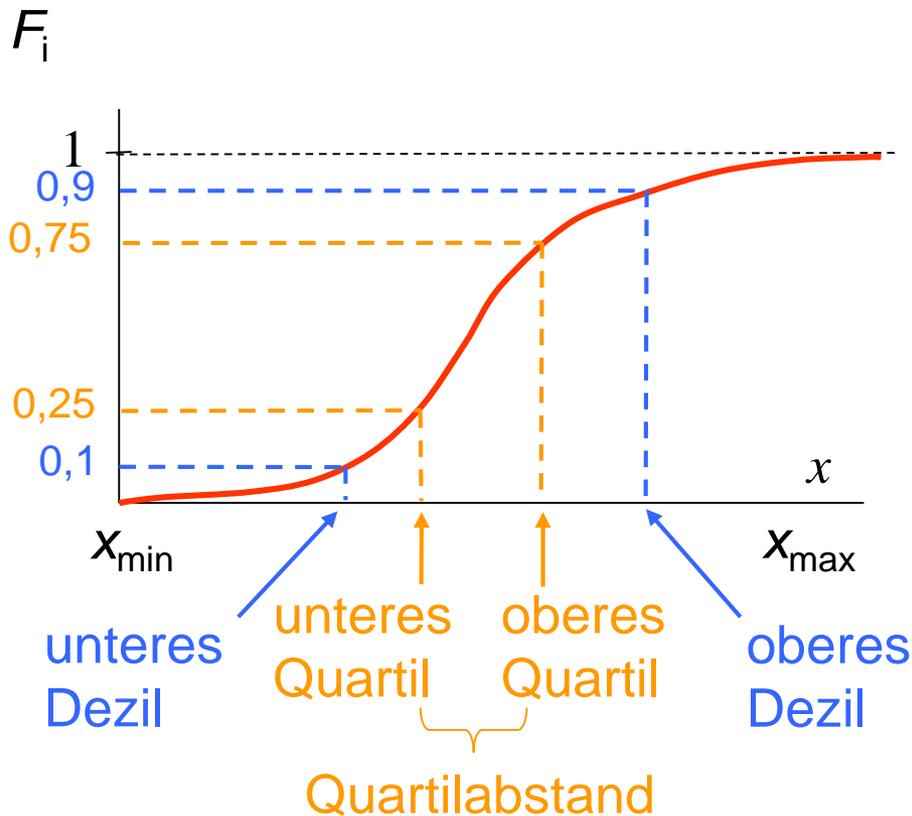
## Wirkung der Chemotherapie. Pankreaskarzinom

kumulatives  
Überleben  
nach der  
Operation

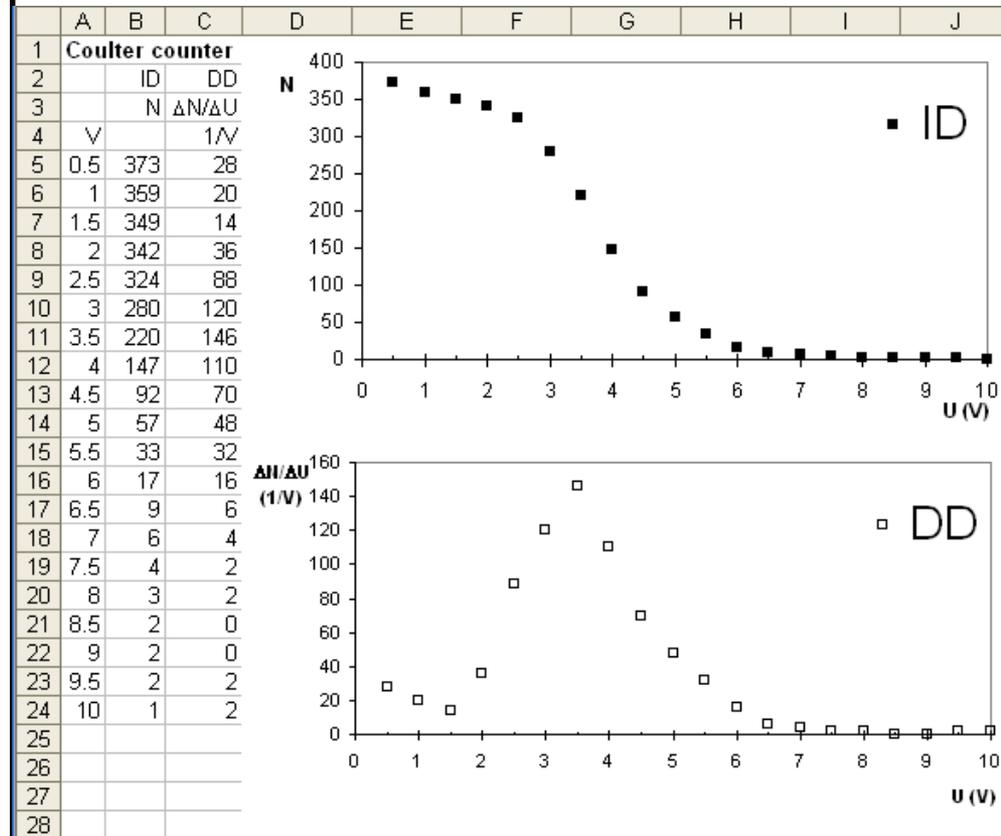


Überleben, Tage

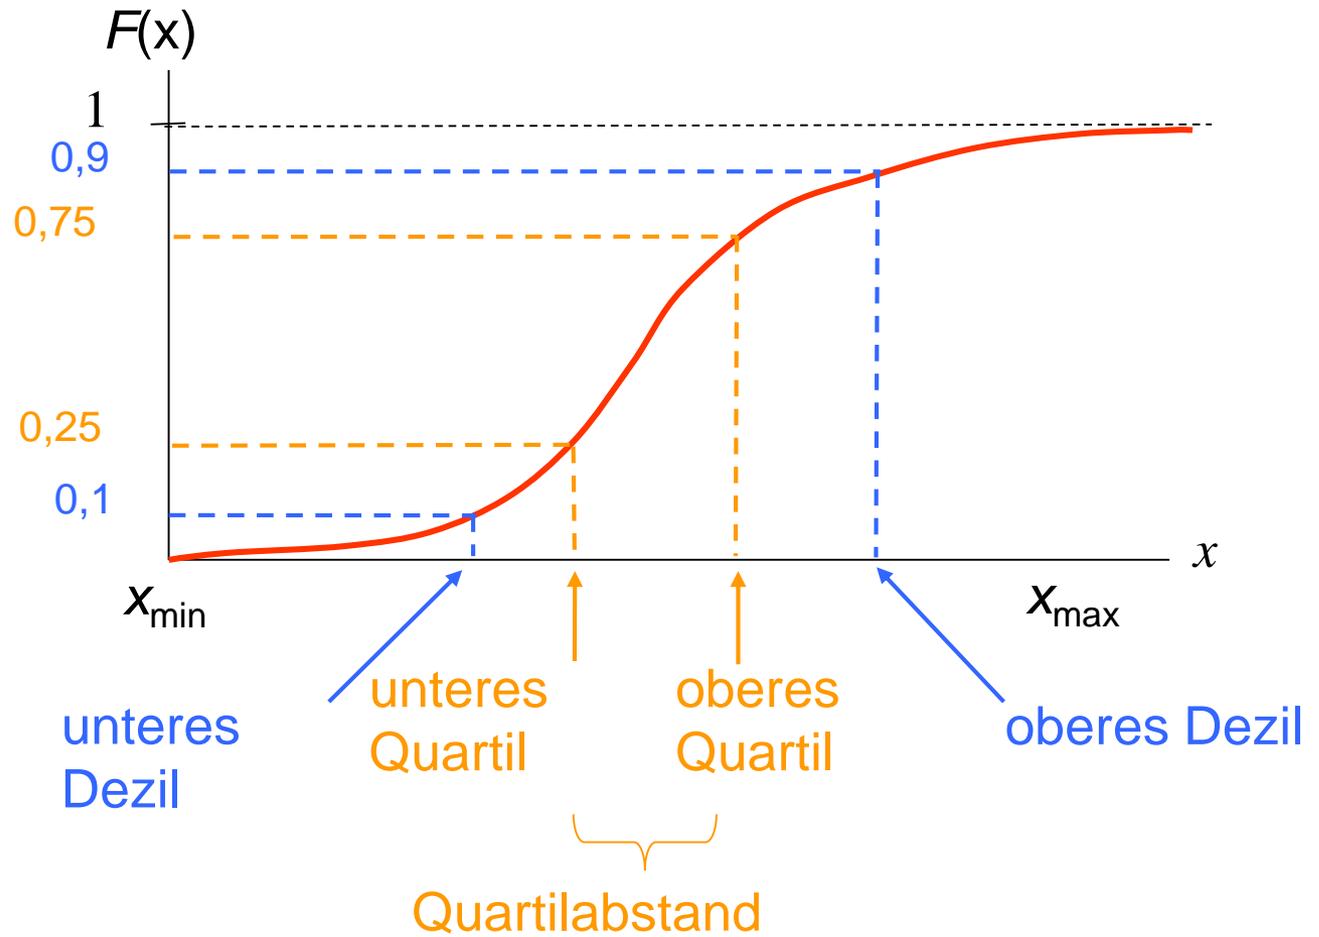
# Quantile und die relative Summenhäufigkeits- verteilung



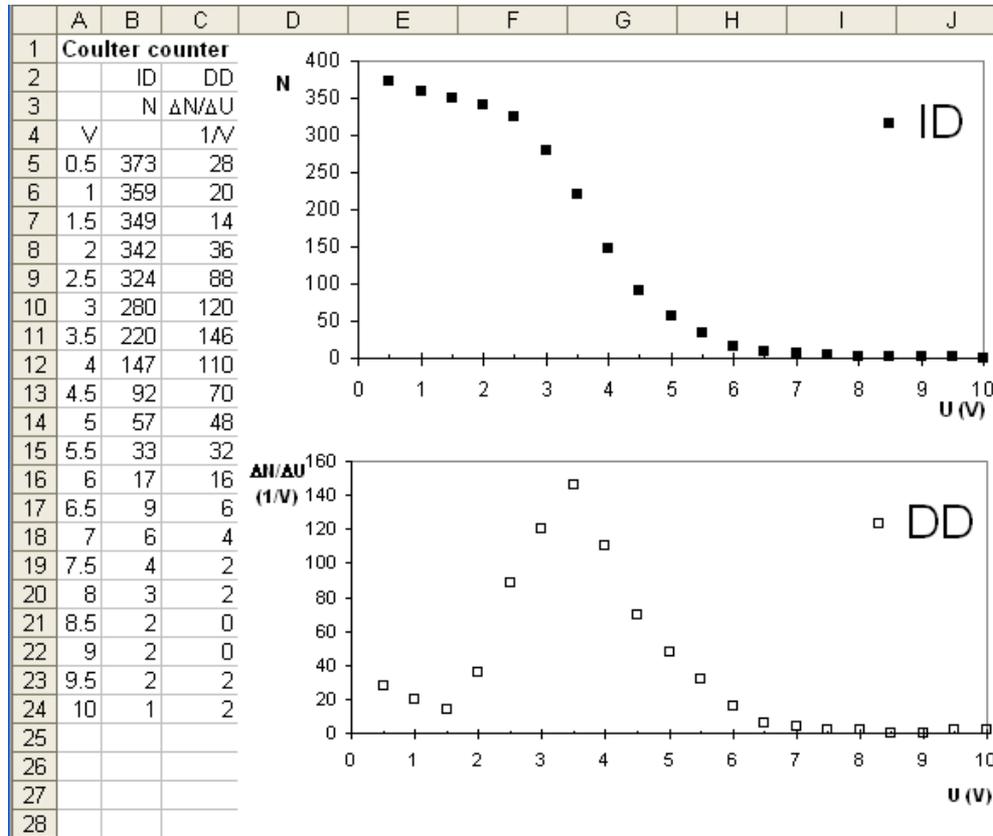
Beispiel in der  
Physikpraktikum:  
Coulter Zähler  
(siehe viel später...)



# Quantile und die relative Summenhäufigkeits-verteilung



**Beispiel in der  
Physikpraktikum:  
Coulter Zähler  
(siehe viel später...)**



# Verteilungen und Schätzungen

## Grundlagen der Wahrscheinlichkeitslehre



# Zufallsexperiment

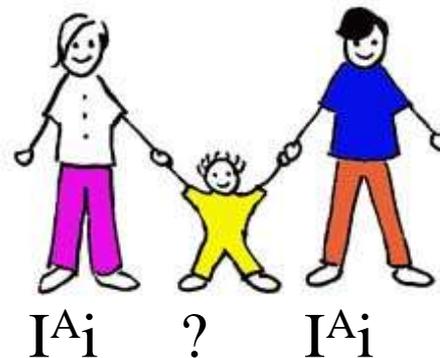
- Vorgang nach einer bestimmten Vorschrift ausgeführt
- (im Prinzip) beliebig oft wiederholbar
- sein Ergebnis ist zufallsabhängig (in der Natur ist es immer!)  
Es gibt eine eingebaute Unsicherheit in der Natur.
- bei mehrmaligen Durchführung des Experiments beeinflussen die Ergebnisse einander nicht



Würfelspiel



Roulett



Blutgruppenversuch

# Elementarereignisse

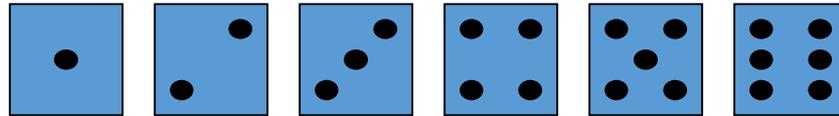
die einzelnen, nicht mehr zerlegbaren und sich gegenseitig ausschliessenden Ausgänge oder Ergebnisse eines Zufallsexperimentes

## Ereignismenge, Ereignisraum ( $\Omega$ )

Reihe aller möglichen Elementarereignisse. Z.B:

beim Würfelspiel:

$$\Omega = \{1, 2, 3, 4, 5, 6\}$$



beim Münzenexperiment:  $\Omega = \{\text{Zahl}, \text{Kopf}\}$



beim „Blutgruppenversuch“:  $\Omega = \{I^A I^A, I^A i, i I^A, ii\}$

# Wahrscheinlichkeit

Bernoulli (1654-1705), Laplace (1749-1827)  
(**klassische Wahrscheinlichkeit**)

Bei einem Zufallsexperiment, was endlich viele Ausgänge hat, die (zB. wegen Symmetriegründen) **gleichwahrscheinlich** sind, die Wahrscheinlichkeit eines Ereignisses ( $E$ ) ist:

$$p(E) = \frac{\text{Anzahl der für } E \text{ günstigen Elementarereignisse}}{\text{Anzahl aller gleichmöglichen Elementarereignisse}}$$

Dabei denken wir, dass alle interessante Ereignisse eigentlich aus Kombinationen verschiedener Elementarereignisse aufbaubar sind, der Anzahl wovon kann auch sehr gross sein (wie im Lego-Spiel).

$p$ =probability, Probabilität

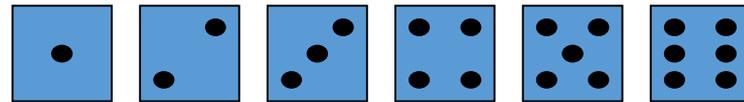
$$p(E) = \frac{g}{m}$$

← günstig

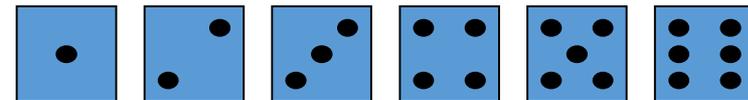
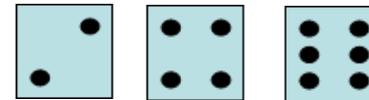
← alle

Würfelexperiment:

$$p(6) = \frac{1}{6}$$



$$p(\text{gerade Zahl}) = \frac{3}{6}$$



Münzenexperiment:

$$p(\text{Kopf}) = \frac{1}{2}$$



# Statistische Wahrscheinlichkeit:

oft sind die Elementarereignisse NICHT gleich wahrscheinlich!

Zufallsexperiment



Ereignis A



Ereignis B



Gefälschte Münze?

Tritt bei  $n$ -maliger Durchführung eines Zufallsexperimentes ein bestimmtes Ereignis **A**  $k$ -mal auf, so bezeichnet man die in langen Versuchsreihen zu beobachtende relative Häufigkeit als

**Wahrscheinlichkeit,  $p(A)$  :**

$$p(A) = \frac{k}{n}$$

Wenn  $n \rightarrow$  unendlich

# Eigenschaften der Wahrscheinlichkeit

→  $0 \leq p(A) \leq 1$

→  $p(\text{sicheres Ereignis}) = 1$

→  $p(\text{unmögliches Ereignis}) = 0$

# Verteilungen

Population



Wahrscheinlichkeitsverteilung

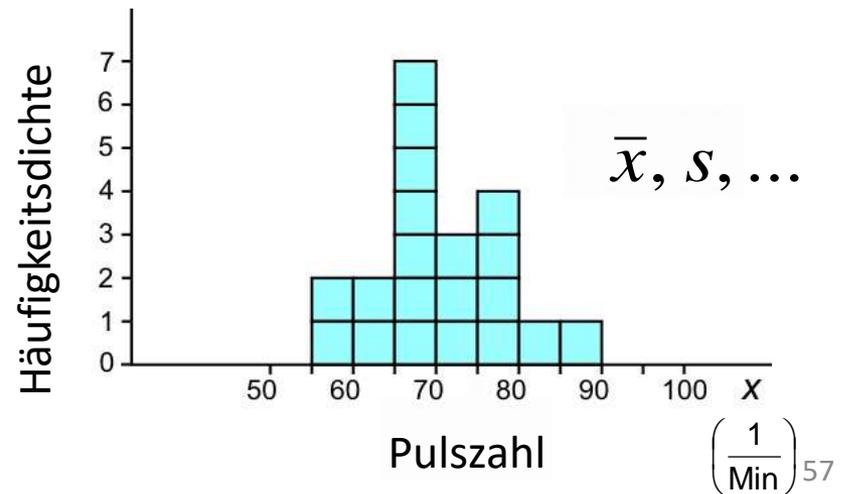


?, ?, ...

Stichprobe



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

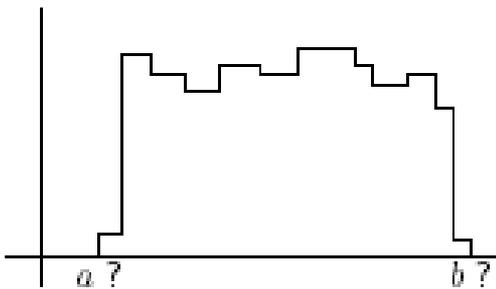


# Verteilungen

Wie kann man die theoretische Verteilung bestimmen?

Vermutung

(nach dem Histogramm)



Gleichverteilung?

Modellannahme



**Laplace-Prinzip:**

wenn nichts dagegen spricht, gehen wir davon aus, dass alle Elementarereignisse gleich wahrscheinlich sind

Laplace-Experiment:

es meint ein Zufalls-Experiment bei dem davon ausgegangen wird, dass jeder Versuchsausgang **gleichwahrscheinlich** ist



Gleichverteilung der Elementarereignisse

# Klassifizierung der Verteilungen

- **diskrete Verteilungen**

- diskrete Gleichverteilung
- Binomialverteilung
- Poisson Verteilung
- ...

diskrete Zufallsgröße

zB: Anzahl der Kranken,  
Augenzahl des Würfels

- **kontinuierliche Verteilungen**

- kontinuierliche Gleichverteilung
- Normalverteilung
- Chi-Quadrat Verteilung
- *t*-Verteilung
- ...

kontinuierliche Zufallsgröße

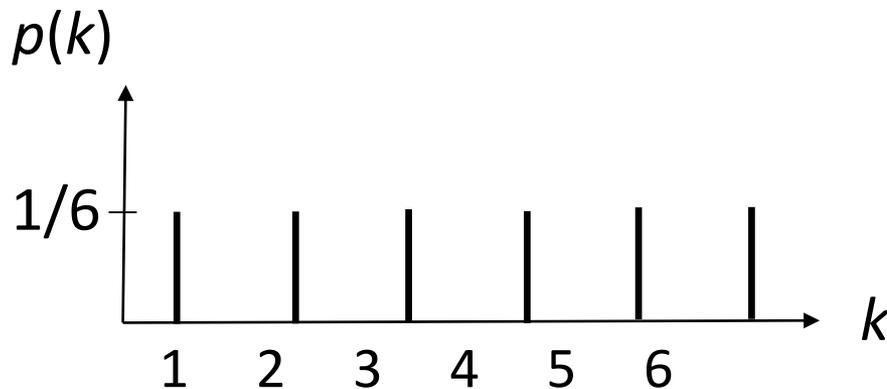
zB: Blutdruck, Körperhöhe,...

# Diskrete Gleichverteilung



Beispiel:

Wertebereich	1	2	3	4	5	6
Wahrscheinlichkeit	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$	$\frac{1}{6}$



$$p(k) = \frac{1}{6}, \quad k = 1, 2, \dots, 6$$

*weitere Beispiele:*

Münzenversuch



Würfelexperiment  
mit einem Ikosaeder



## Lageparameter der Verteilung

Es sei  $X$  eine diskrete Zufallsgröße mit Werten  $x_1, x_2, \dots$  dann heisst

$$\mu = \sum_i x_i p(x_i)$$

**Erwartungswert** von  $X$ .

Der Erwartungswert gibt denjenigen Wert an, den man als Mittelwert (durchschnittlichen Wert) über viele Versuchswiederholungen “erwarten” kann.

Dabei ist es durchaus möglich, dass der Erwartungswert bei keinem einzigen Versuch realisiert wird oder sogar überhaupt nicht vorkommen kann.

# Erwartungswert und Durchschnittswert

$$\mu = \sum_i x_i p(x_i)$$

$$\bar{x} = \sum_i x_i h_i$$

Beispiel: 100 Würfelexperimente. 2,5,4,3,6,6,1,5,4,2,3...

Insgesamt:

Rel.Häufigkeit

$x_i$	$n_i$	$h_i$
1	15	15/100
2	20	20/100
3	14	14/100
4	16	16/100
5	18	18/100
6	17	17/100

$$\bar{x} = \frac{15 \cdot 1 + 20 \cdot 2 + 14 \cdot 3 + 16 \cdot 4 + 18 \cdot 5 + 17 \cdot 6}{100} =$$

$$= \frac{15}{100} \cdot 1 + \frac{20}{100} \cdot 2 + \frac{14}{100} \cdot 3 + \frac{16}{100} \cdot 4 + \frac{18}{100} \cdot 5 + \frac{17}{100} \cdot 6 = 3.53 =$$

$$= h(1) \cdot 1 + h(2) \cdot 2 + h(3) \cdot 3 + h(4) \cdot 4 + h(5) \cdot 5 + h(6) \cdot 6 \rightarrow$$

$$\xrightarrow{n \rightarrow \infty} P(1) \cdot 1 + P(2) \cdot 2 + P(3) \cdot 3 + P(4) \cdot 4 + P(5) \cdot 5 + P(6) \cdot 6 = \mu$$

$x_i$ : Augenzahl

$n_i$ : absolute Häufigkeit

$h_i$ : relative Häufigkeit

$$\bar{x} \xrightarrow{n \rightarrow \infty} \mu$$

# Streuung der Verteilung

Es sei  $X$  eine diskrete Zufallsgröße mit Werten  $x_1, x_2, \dots$  und mit dem Erwartungswert  $\mu$ . Dann nennt man die Zahl

$$\sigma^2 = \sum_i (x_i - \mu)^2 p(x_i)$$

als Varianz von  $X$ , ihre Wurzel als (theoretische) Streuung ( $\sigma$ ).

$$S \xrightarrow{n \rightarrow \infty} \sigma$$

empirische → theoretische  
Streuung      Streuung

(Standardabweichung)

# Normalverteilung

Verteilungsdichtefunktion:

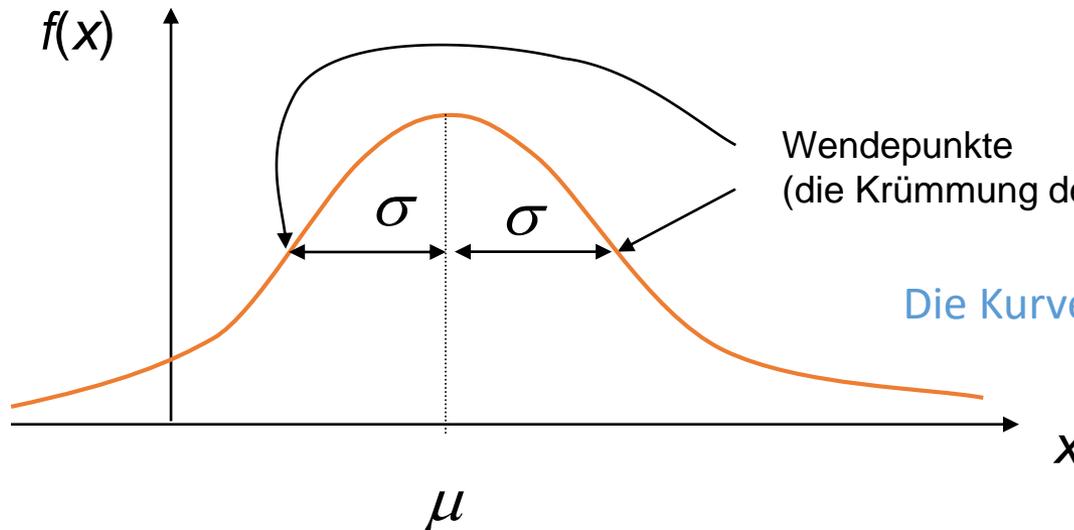
Parameter der Normalverteilung:

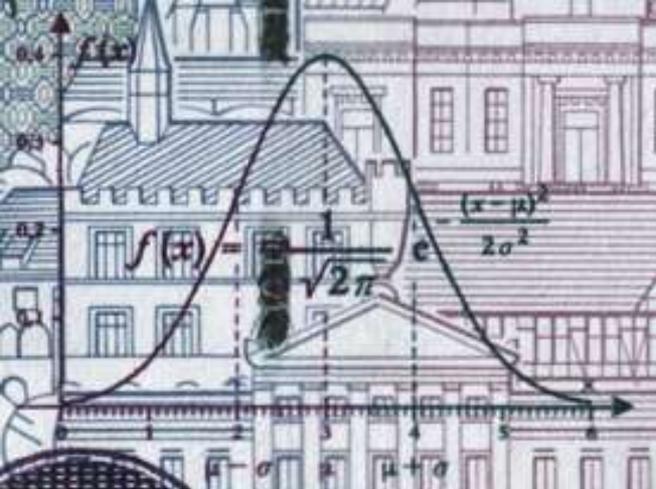
Erwartungswert:  $\mu$

Streuung:  $\sigma$

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Oberfläche unter der Kurve = 1.  
(gilt für alle verteilungsdichtefunktionen!)





# Normalverteilung (Gauss-Verteilung)

für die dargestellte Funktion:  $\mu = 3, \sigma = 1$

DL0998939U1



Deutsche Bundesbank

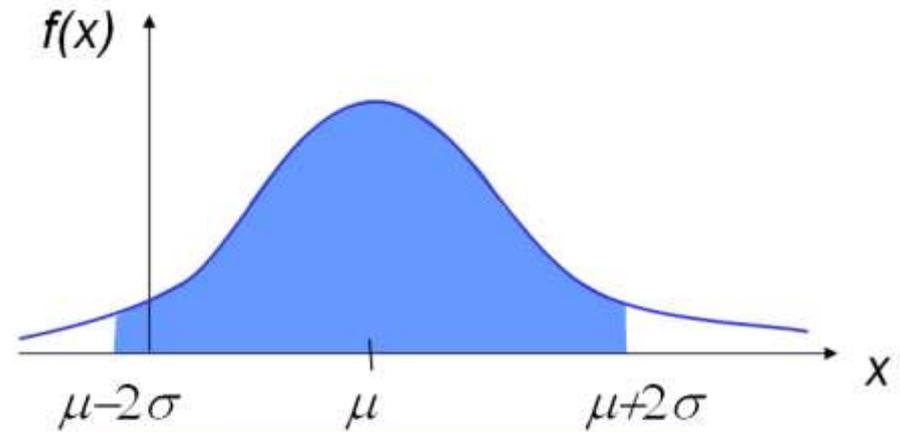
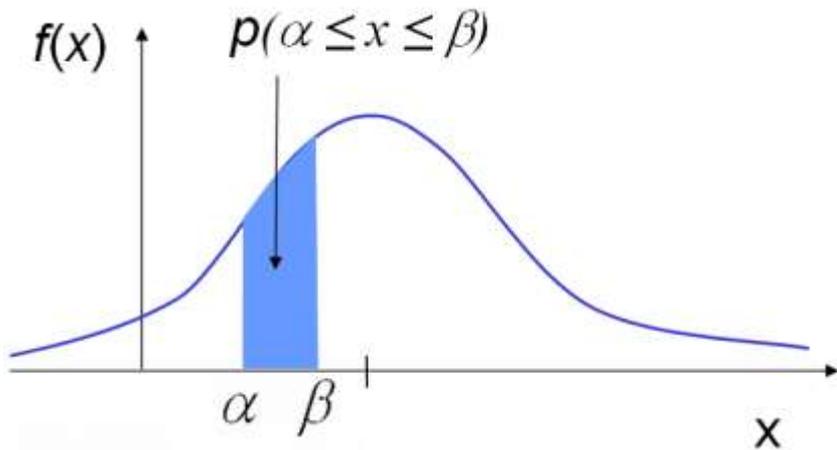
*Heinrich Jaeger*  
Frankfurt am Main  
1 Oktober 1993



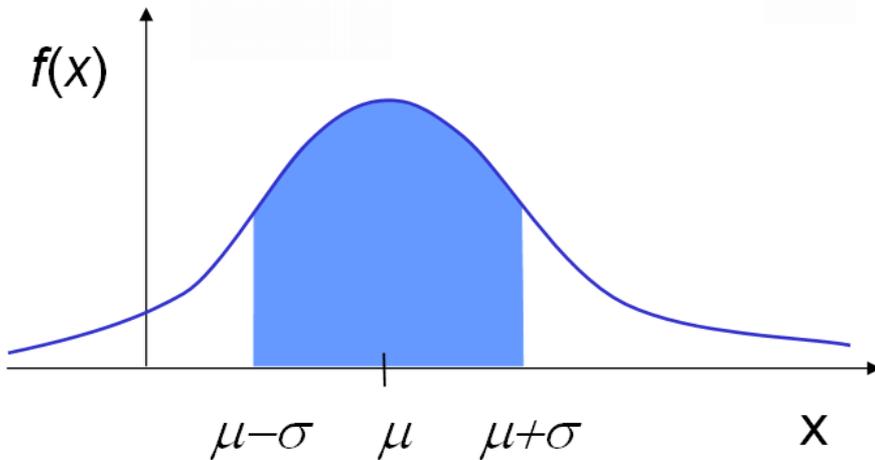
DL0998939U1

# Normalverteilung

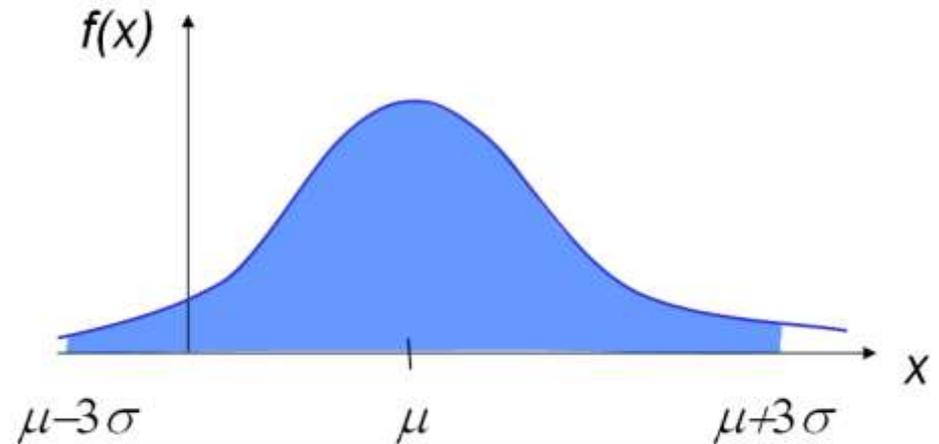
Wahrscheinlichkeit ist eine Oberfläche unter der Dichtefunktion!



$$p(\mu - 2\sigma \leq x \leq \mu + 2\sigma) = 95\%$$



$$p(\mu - \sigma \leq x \leq \mu + \sigma) = 68\%$$



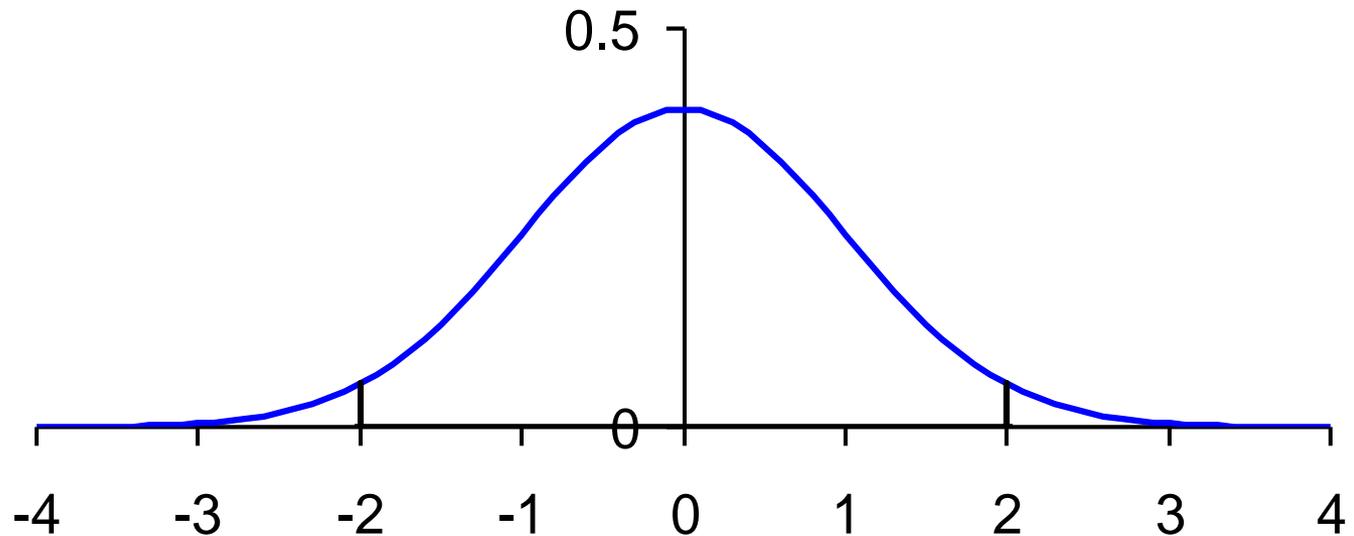
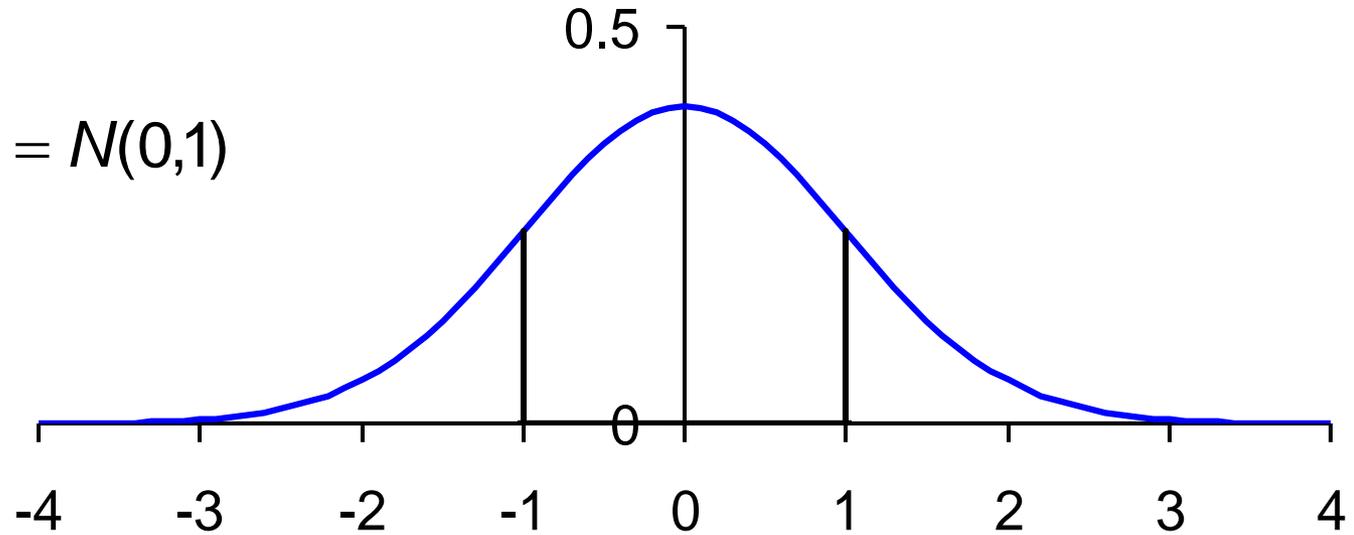
$$p(\mu - 3\sigma \leq x \leq \mu + 3\sigma) = 99,8\%$$

# Standard - Normalverteilung

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} = N(0,1)$$

$$\mu = 0$$

$$\sigma = 1$$

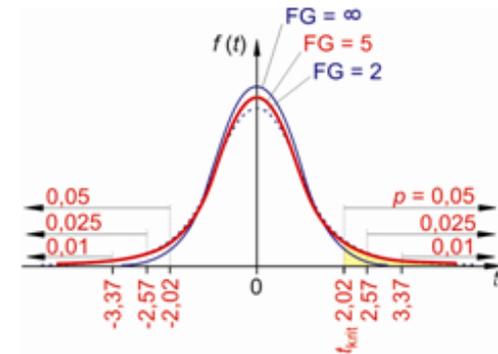


# 1. STATISTISCHE TABELLEN

## t-VERTEILUNG

Freiheitsgrad (FG)	$p$ (Irrtumswahrscheinlichkeit, einseitiger Test)						
	0,4	0,25	0,1	0,05	0,025	0,01	0,005
	$p$ (Irrtumswahrscheinlichkeit, zweiseitiger Test)						
	0,8	0,5	0,2	0,1	0,05	0,02	0,01
1	0,325	1,000	3,078	6,314	12,70	31,82	63,65
2	0,289	0,816	1,886	2,920	4,303	6,965	9,925
3	0,277	0,765	1,638	2,353	3,182	4,541	5,841
4	0,271	0,741	1,533	2,132	2,776	3,747	4,604
5	0,267	0,727	1,476	2,015	2,571	3,365	4,032
6	0,265	0,718	1,440	1,943	2,447	3,143	3,707
7	0,263	0,711	1,415	1,895	2,365	2,998	3,499
25	0,256	0,684	1,316	1,708	2,060	2,485	2,787
26	0,256	0,684	1,315	1,706	2,056	2,479	2,779
27	0,256	0,684	1,314	1,703	2,052	2,473	2,771
28	0,256	0,683	1,313	1,701	2,048	2,467	2,763
29	0,256	0,683	1,311	1,699	2,045	2,462	2,756
30	0,256	0,683	1,310	1,697	2,042	2,457	2,750
40	0,255	0,681	1,303	1,684	2,021	2,423	2,704
60	0,255	0,679	1,296	1,671	2,000	2,390	2,66
120	0,254	0,677	1,289	1,658	1,980	2,358	2,617
$\infty$	0,250	0,674	1,282	1,645	1,960	2,326	2,576

# t-Verteilungsfamilie



„Glockenkurven“

Je größer ist der Freiheitsgrad, desto schmaler ist die Kurve.

Also der Freiheitsgrad ist ein Zahl um eine bestimmte Kurve auszuwählen.

$$t_{\infty} \equiv N(0, 1)$$



# Zentraler Grenzwertsatz

- Es seien  $x_1, x_2, \dots, x_n$  unabhängige Zufallsgrößen, die alle derselben Verteilung haben.

- Die **Verteilung der Summe** nähert sich einer **Normalverteilung**, wenn  $n \rightarrow \infty$  .  $S_n = \sum_{i=1}^n x_i$

- Die Summe der Verteilungsfunktionen konvergiert gegen eine Normalverteilung auch wenn die einzelnen Zufallsgrößen keine Normalverteilung haben.

- Biologische Bedeutung:**

**Wenn ein Parameter (zB. Körpergröße, Blutzuckerkonzentration) durch viele anderen Faktoren (Zufallsgrößen) beeinflusst wird, folgt dieser Parameter einer Normalverteilung.**

# Analytische Statistik



Population

$N = \text{„unendlich“}$

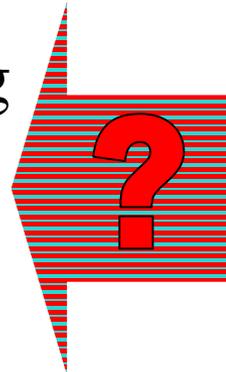


Stichprobe

$n = \text{endlich}$



Theoretische Verteilung  
Erwartungswert  
Theoretische Streuung



Häufigkeitsverteilung  
Durchschnitt  
Standardabweichung

# Aufgabe der Schätztheorie

Aus einer Stichprobe Schätzwerte für

- Wahrscheinlichkeiten
- Erwartungswert
- Streuung
- oder andere Parametern

einer Verteilung zu ermitteln.

Typen der Schätzungen:

- *Punktschätzung*
- *Intervallschätzung*

# Punktschätzungen

- Der Parameter wird mit einem Wert geschätzt.
- Relative Häufigkeit  
ist ein Schätzwert für die Wahrscheinlichkeit
- Durchschnitt  
ist ein Schätzwert für den Erwartungswert
- Standardabweichung  
ist ein Schätzwert für die Streuung
- Punktschätzungen sagen  
***nichts über die Genauigkeit bzw. Sicherheit*** der Schätzung!

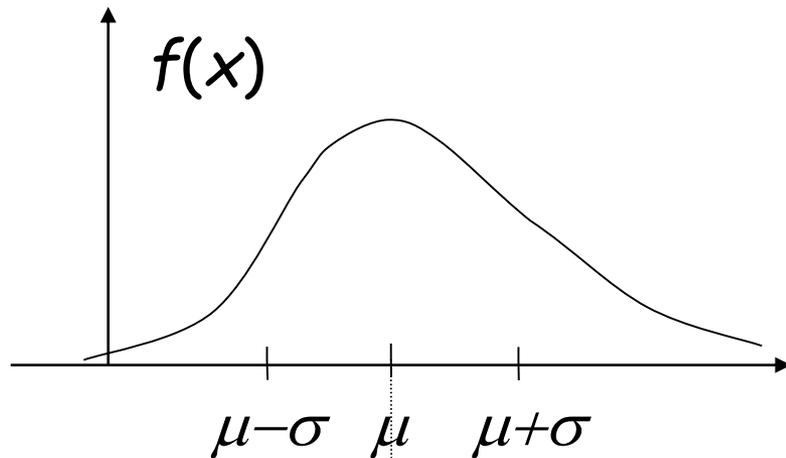
# Intervallschätzungen

- Intervallschätzung oder Konfidenzschätzung gibt zu einer vorgewählten Sicherheitswahrscheinlichkeit  $\gamma$ , (Konfidenzniveau) ein Intervall  $(c_1, c_2)$  an, in dem der unbekannte Parameter (zB.  $\mu$  oder  $\sigma$ ) mit einer Wahrscheinlichkeit von mindestens  $\gamma$  liegt.

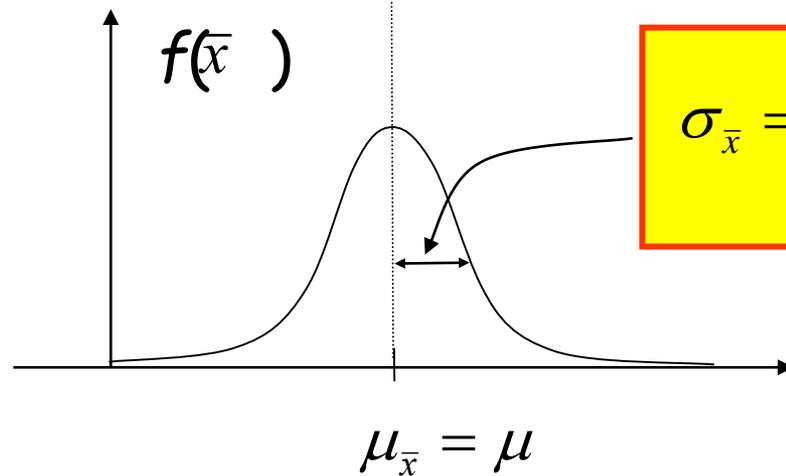


Zb.: Erwartungswert der Pulszahl ist bei  
95% Konfidenzniveau:  $74 \pm 6$  <sup>1/</sup>Min

# Konfidenzintervall für den Erwartungswert



$x$  zB: Körperhöhe

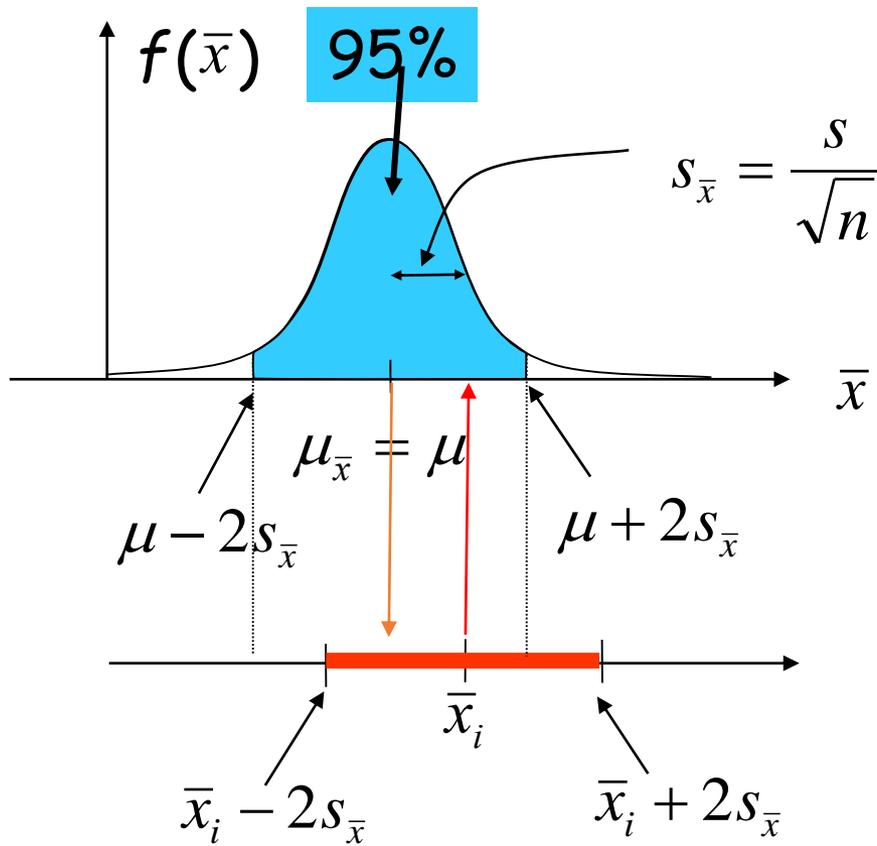


$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} \approx s_{\bar{x}}$$

Standardfehler

$\bar{x}$  zB: durchschnittliche Körperhöhe in einem Studentengruppe von  $n$  Studenten

# Konfidenzintervall für den Erwartungswert



$\bar{x}_i$  liegt mit 95% Wahrscheinlichkeit im Intervall  $\mu - 2s_{\bar{x}}$   $\mu + 2s_{\bar{x}}$

Und gleichzeitig mit 100-95= 5% Wahrscheinlichkeit irgendwo draussen!

wenn  $\mu - 2s_{\bar{x}} \leq \bar{x}_i \leq \mu + 2s_{\bar{x}}$  dann

$\bar{x}_i - 2s_{\bar{x}} \leq \mu \leq \bar{x}_i + 2s_{\bar{x}}$

95% Wahrsch.

95% Wahrsch.

Konfidenzintervall für den Erwartungswert

In dem Intervall  $\bar{x} - 2s_{\bar{x}}, \bar{x} + 2s_{\bar{x}}$  **Konfidenzintervall**  
liegt der Erwartungswert ( $\mu$ ) mit 95% Wahrscheinlichkeit

Eine ähnliche Ableitung gibt:  $\mu$  liegt

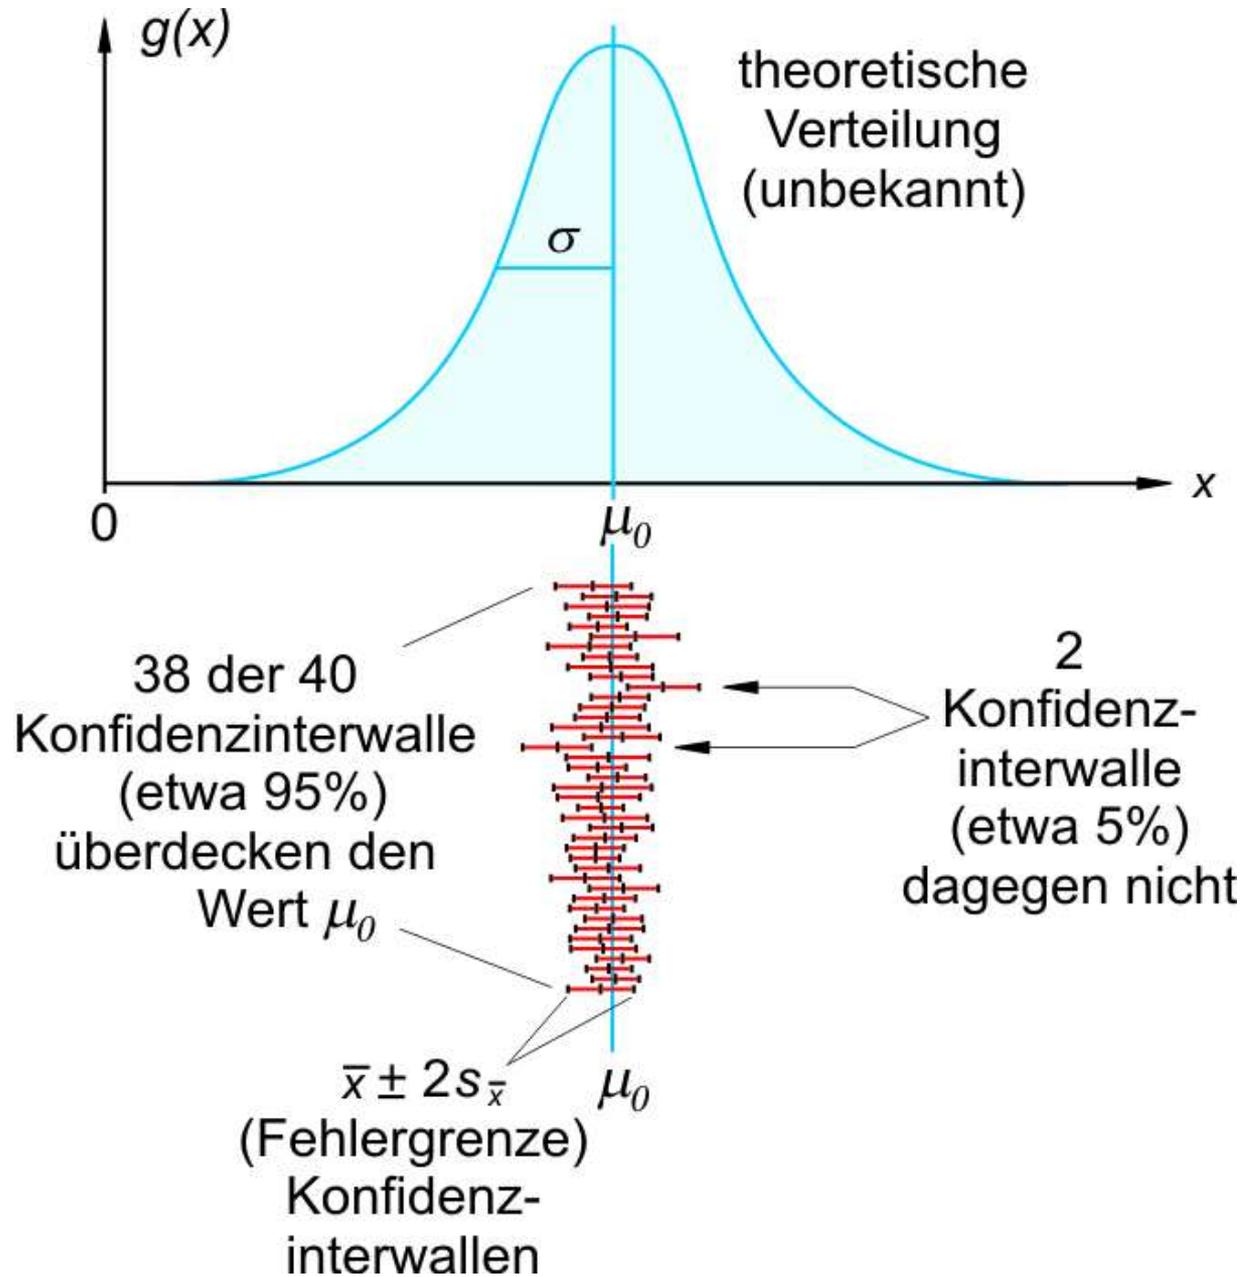
- mit 68% Wahrscheinlichkeit im Intervall:  $\bar{x} - s_{\bar{x}}, \bar{x} + s_{\bar{x}}$

- mit 99,7% Wahrscheinlichkeit im Intervall:

$$\bar{x} - 3s_{\bar{x}}, \bar{x} + 3s_{\bar{x}}$$

**Je größer ist die  
Sicherheitswahrscheinlichkeit desto breiter  
ist das Konfidenzintervall!**

Bemerkung: wenn  $n \rightarrow \infty$  dann  $s_{\bar{x}} \rightarrow 0$



# Zusammenfassung der Schätzungen

- Punktsätzungen:

Stich- probe	Grund- gesamtheit
$\bar{x}$	$\mu$
$s$	$\sigma$
$n$	$\infty$

Intervallschätzung  
für den Erwartungswert:

$$\bar{x} \pm 2s_{\bar{x}} \quad 95\%$$