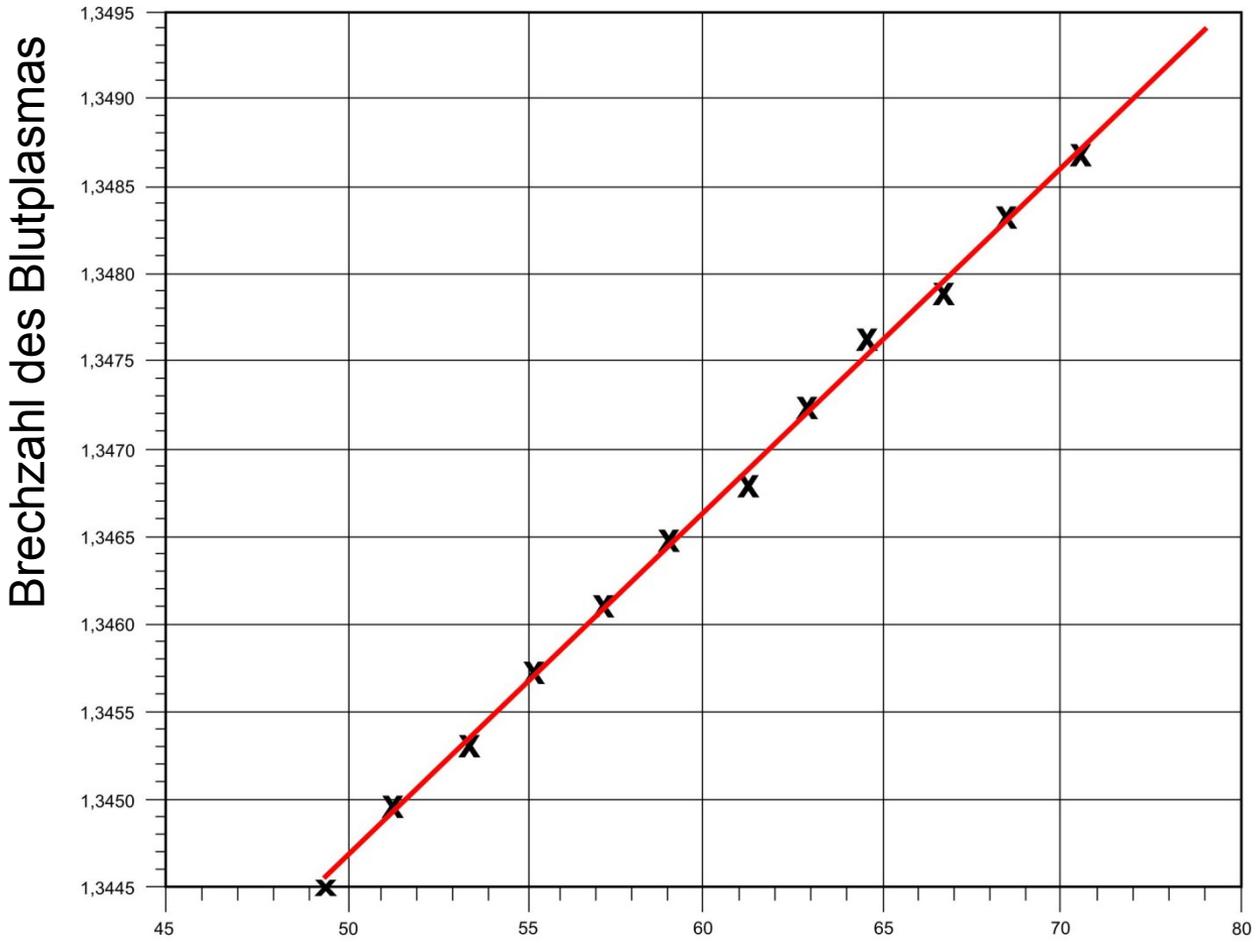


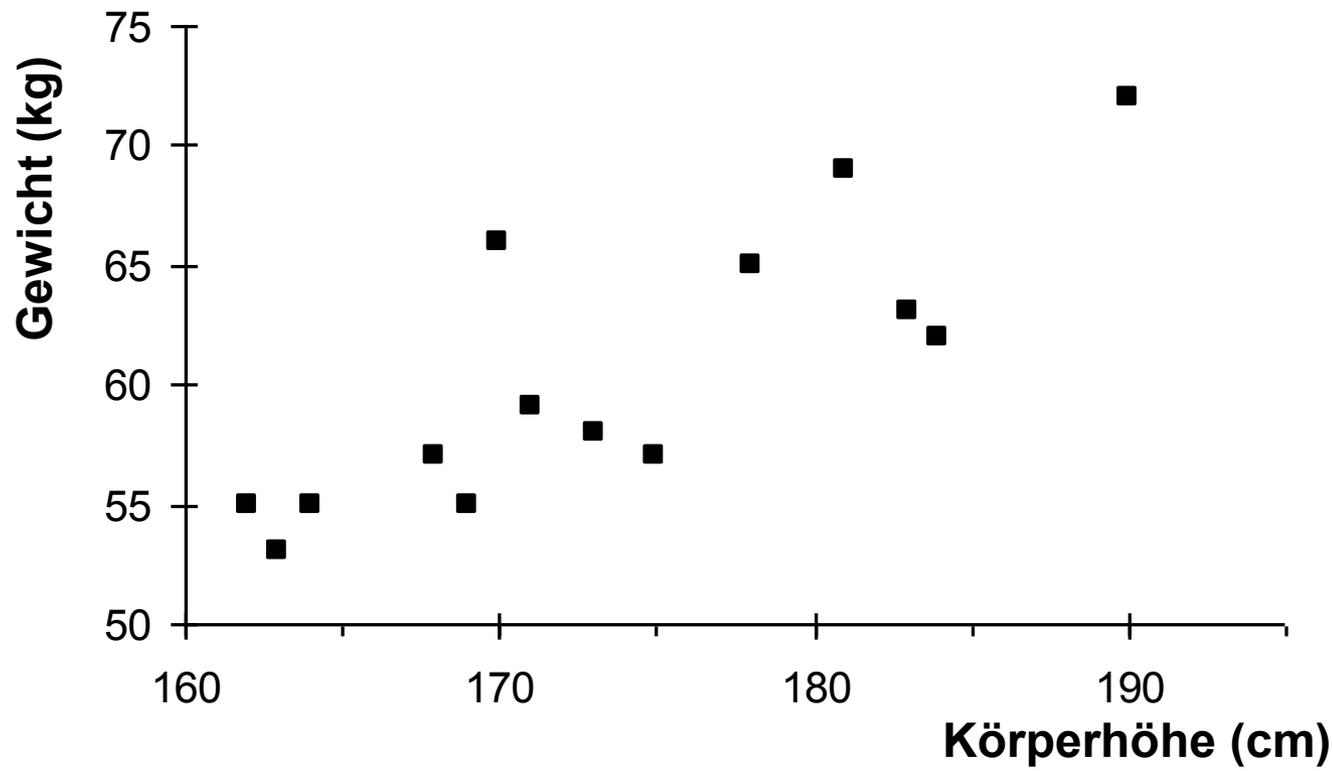
Korrelation

Gibt es ein Zusammenhang?



Plasma-  
eiweiss-  
konzentration  
(g/L)

Daten aus einer Studentengruppe E2  
(Sept. 1994) (zusammengehörige  
Wertepaare)



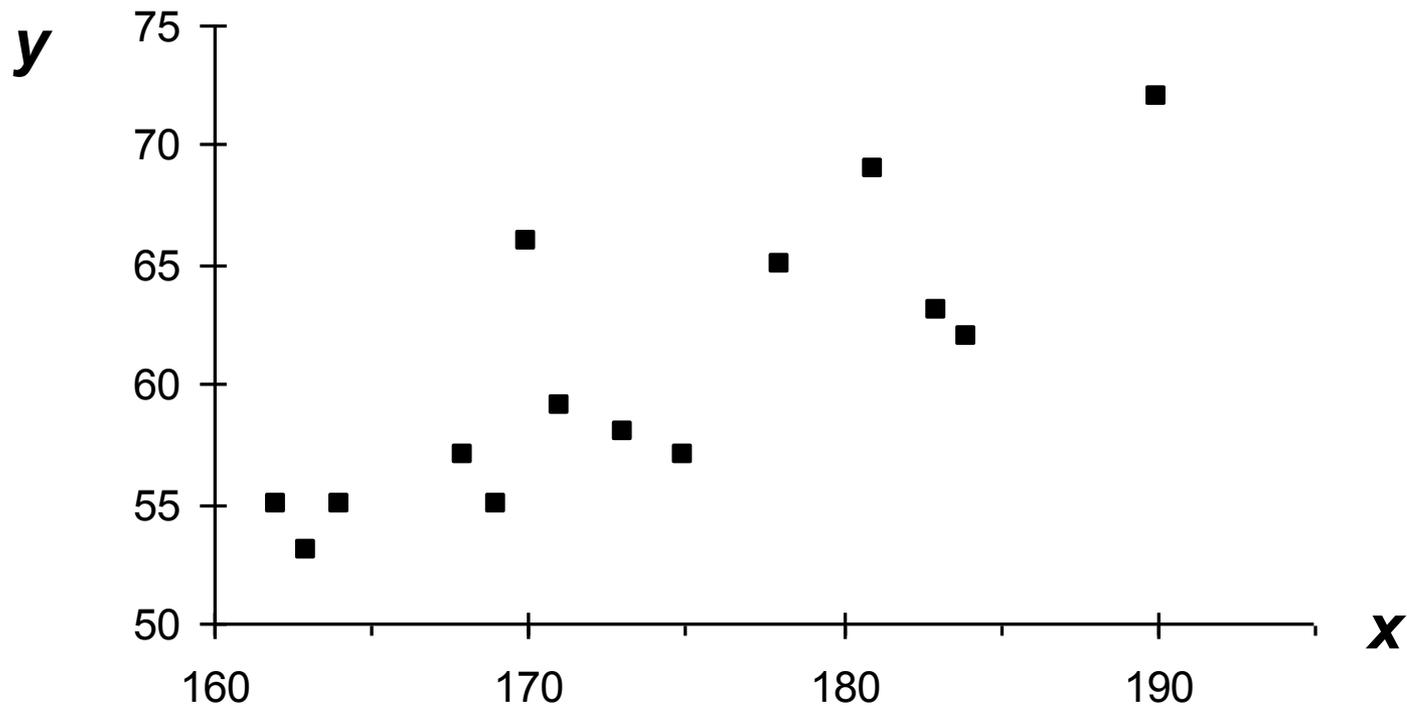
cm	kg
162	55
163	53
164	55
168	57
169	55
170	66
171	59
173	58
175	57
178	65
181	69
183	63
184	62
190	72

was für eine Tendenz kann man bemerken?

Die Korrelationsrechnung beschäftigt sich mit dem symmetrischen Zusammenhang zweier Zufallsgrößen

positive Korrelation: je mehr, desto mehr

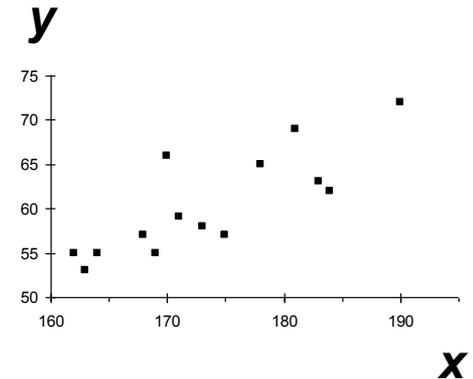
negative Korrelation: je mehr, desto weniger



hier: positive Korrelation

# Regressionsannäherung

Sucht man einen Funktionszusammenhang zwischen einer (oder mehreren) unabhängigen Variable ( $x$ ) und einer abhängigen Variable ( $y$ )



Voraussetzungen:

$x$  und  $y$  numerische und stetige Merkmale,  
 $y$  Zufallsgrösse (ihre Grösse wird nicht nur von der unabhängigen Variable, sondern durch den Zufall beeinflusst)

( $a$ : Steigung,  $b$ : Achsenabschnitt)

Regressionsmodell fixiert den Typ der Funktion:

lineare F.

$$y = (ax + b) + h$$

polinomiale F.

$$y = a + b_1x + b_2x^2 + \dots + b_nx^n + h$$

exponentiale F.

$$y = ab^x + h$$

Potenzfunktion

$$y = ax^b + h$$

und wie wirkt der Zufall auf die abhängige Variable

additiver Fehler ( $+ h$ ) oder multiplikativer Fehler ( $\cdot h$ )

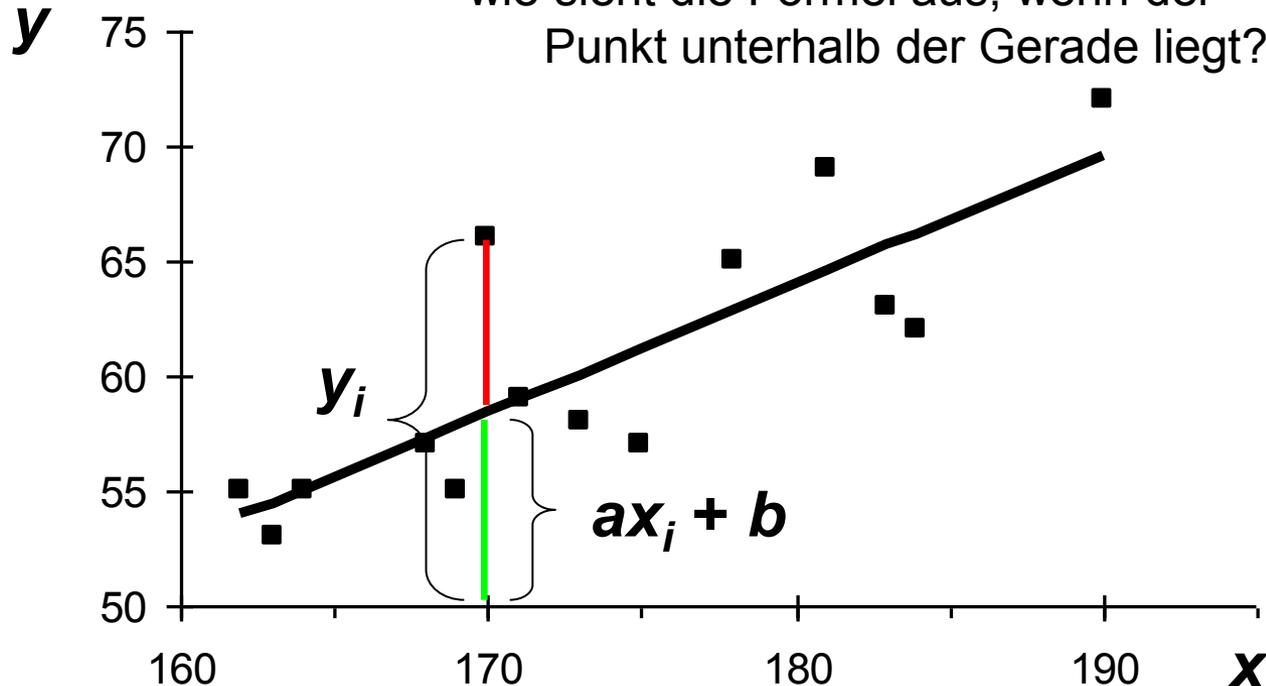
# Das einfachste Regressionsmodell: lineare Regression

lineare Funktion:  $y = (ax + b) + h$

$$h_i = y_i - (ax_i + b)$$

wenn der Punkt  $(x_i, y_i)$  oberhalb der Gerade liegt

wie sieht die Formel aus, wenn der Punkt unterhalb der Gerade liegt?



	$x_i$	$y_i$
1	162	55
2	163	53
3	164	55
4	168	57
5	169	55
6	170	66
7	171	59
8	173	58
9	175	57
10	178	65
11	181	69
12	183	63
13	184	62
14	190	72

Beste Gerade: Summe der Fehlerquadrate ist minimal (Methode der kleinsten Quadraten)

„Die beste“ Steigung:

$$(y = ax + b)$$

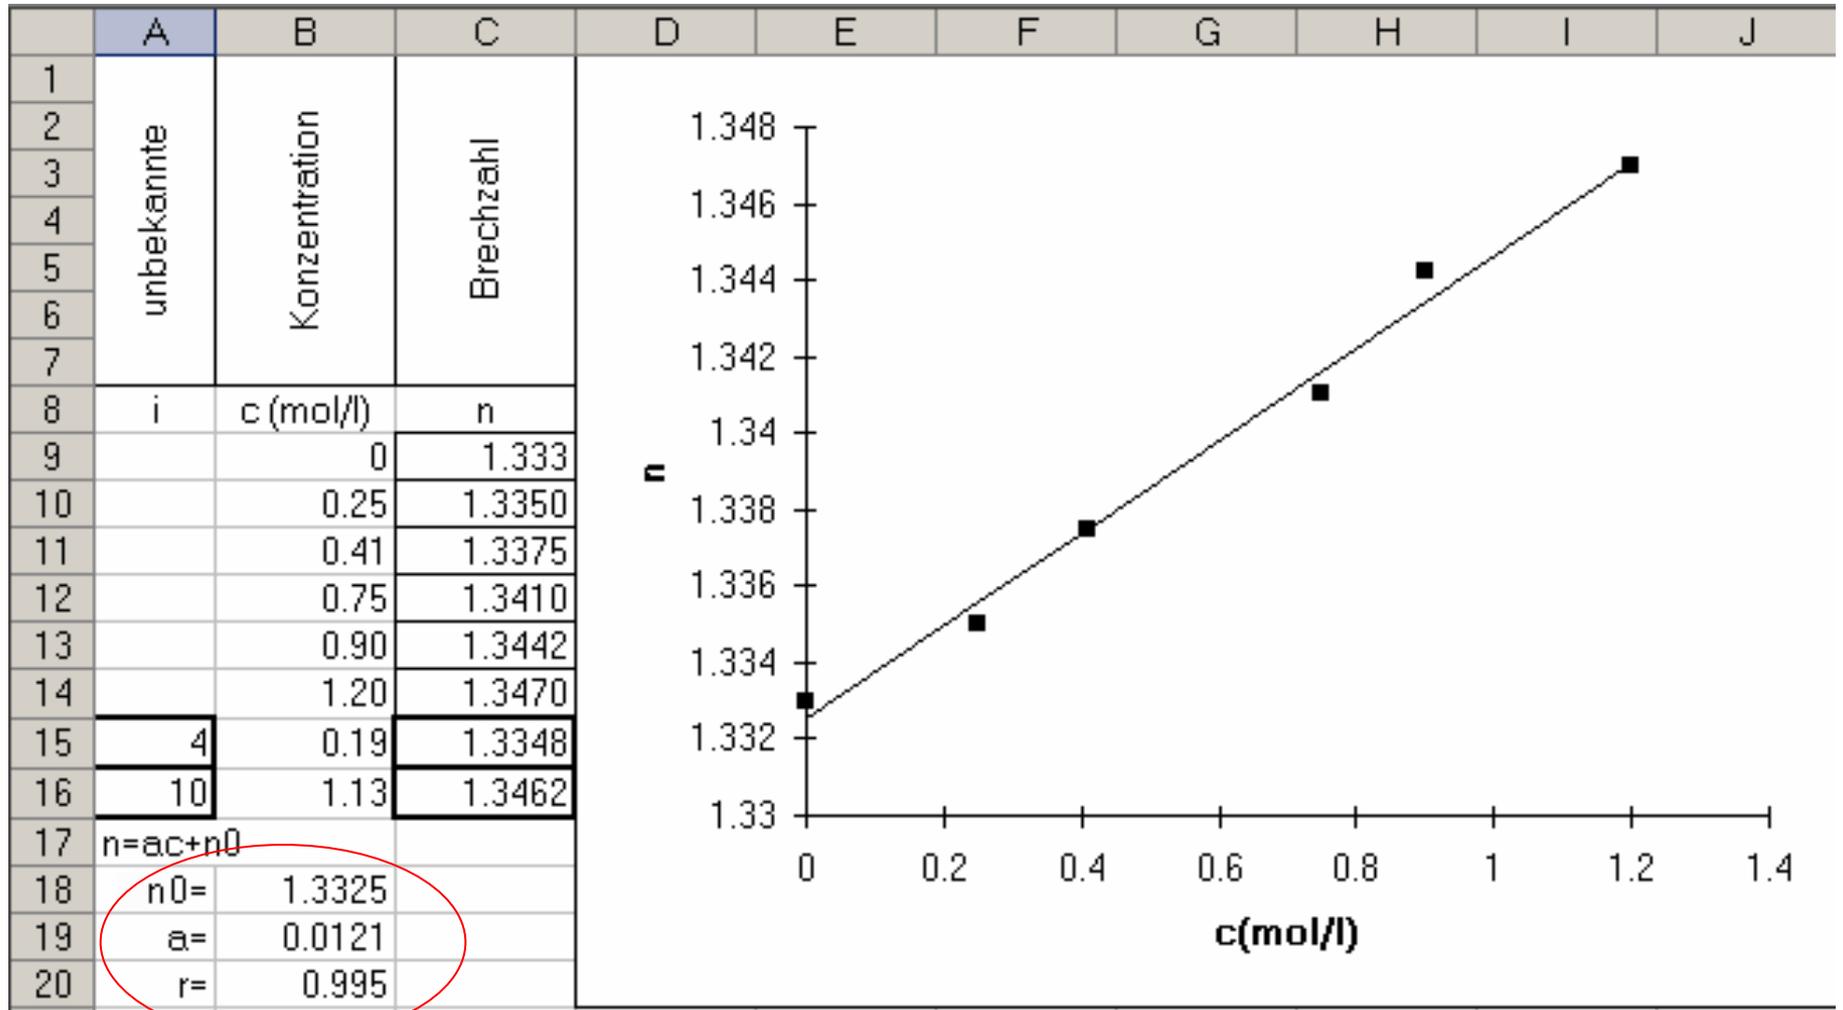
$$a^* = \frac{Q_{xy}}{Q_{xx}} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad \text{oder} \quad a^* = \frac{s_{xy}^2}{s_x^2}$$

„Der beste“ Achsenabschnitt:

$$b^* = \bar{y} - a^* \cdot \bar{x} = \frac{\sum_{i=1}^n y_i}{n} - a^* \frac{\sum_{i=1}^n x_i}{n}$$

wo  $s_{xy}^2 = \frac{Q_{xy}}{n-1}$  : **Kovarianz**

# Beispiel: Refraktometrie



# Wie gut passen die Messpunkte an die Regressionsgerade?

Korrelationsrechnung beschreibt die lineare Beziehung zwischen zwei oder mehr statistischen Variablen

es beschreibt die Stärke der Korrelation  
es gibt starke und schwache Korrelation

Korrelationskoeffizient  
(Pearson)

$$r = \frac{Q_{xy}}{\sqrt{Q_{xx} \cdot Q_{yy}}} = \frac{s_{xy}^2}{s_x s_y}$$

der Zähler ist gleich dem Zähler der Steigung der Regressionsgerade (der Nenner ist in beiden Fall positiv)

$$a^* = \frac{Q_{xy}}{Q_{xx}}$$



positive Steigung:  $r$  ist positive Zahl  
negative Steigung:  $r$  ist negative Zahl

$$-1 \leq r \leq 1$$

weitere Bemerkungen:

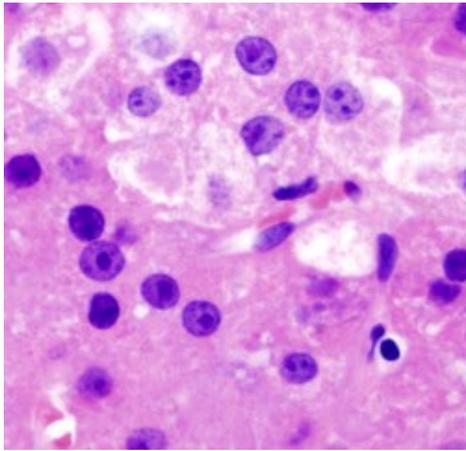
$$-1 \leq r \leq 1$$

Korrelationskoeffizient  
(Pearson)

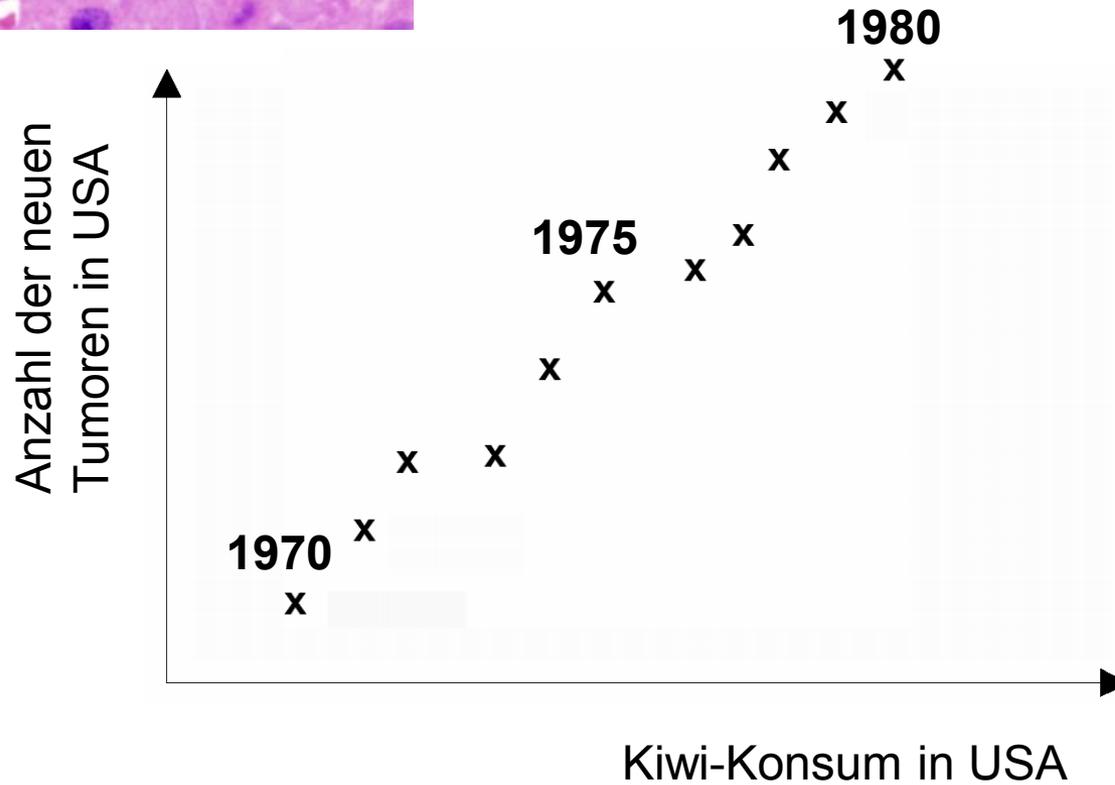
$$0 \leq r^2 \leq 1$$

Bestimmtheitsmass  
(coefficient of determination)

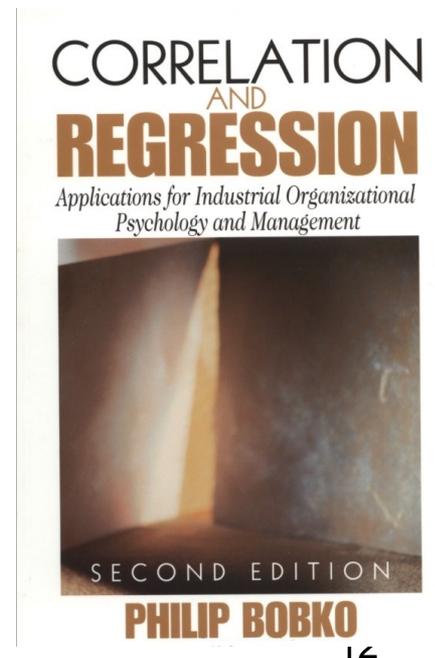
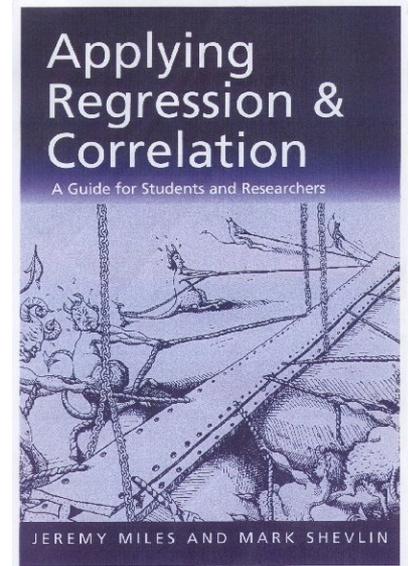
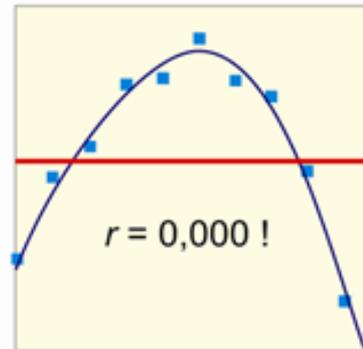
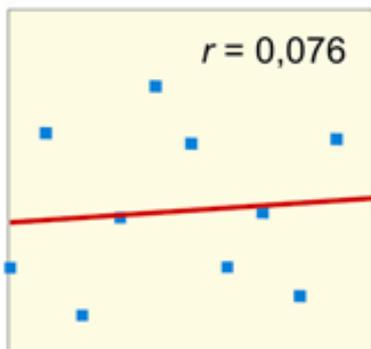
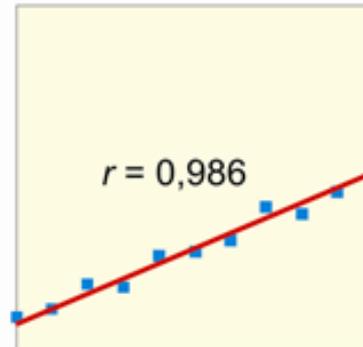
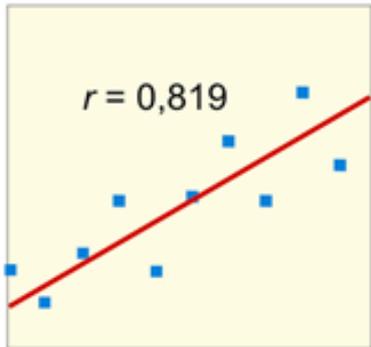
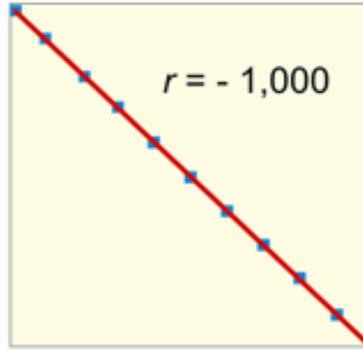
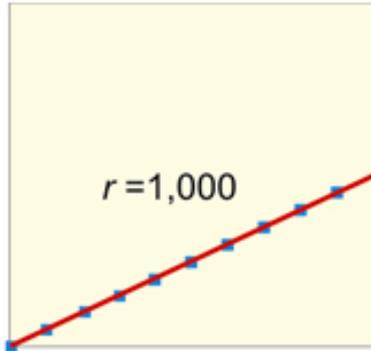
Die Korrelation beschreibt nicht unbedingt eine Ursache-Wirkungs-Beziehung in die eine oder andere Richtung.



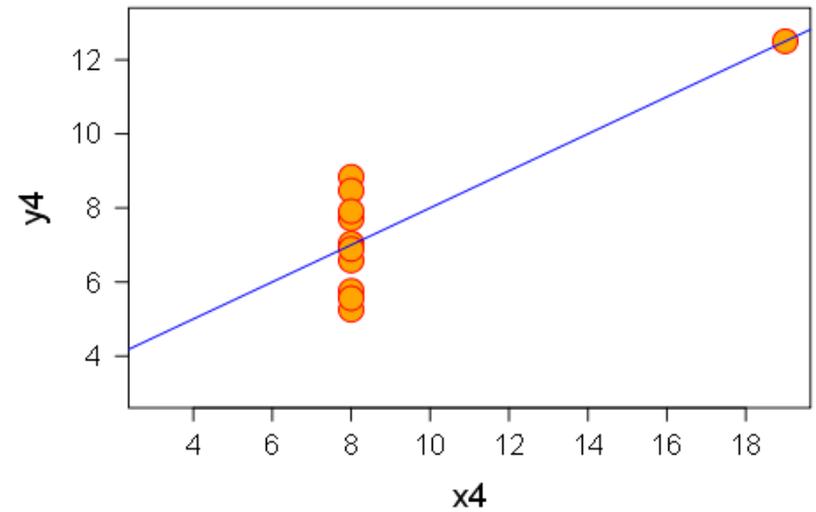
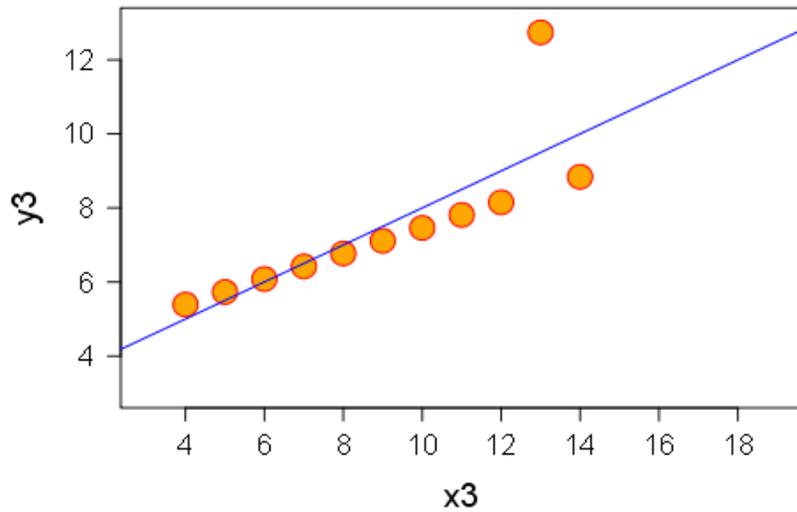
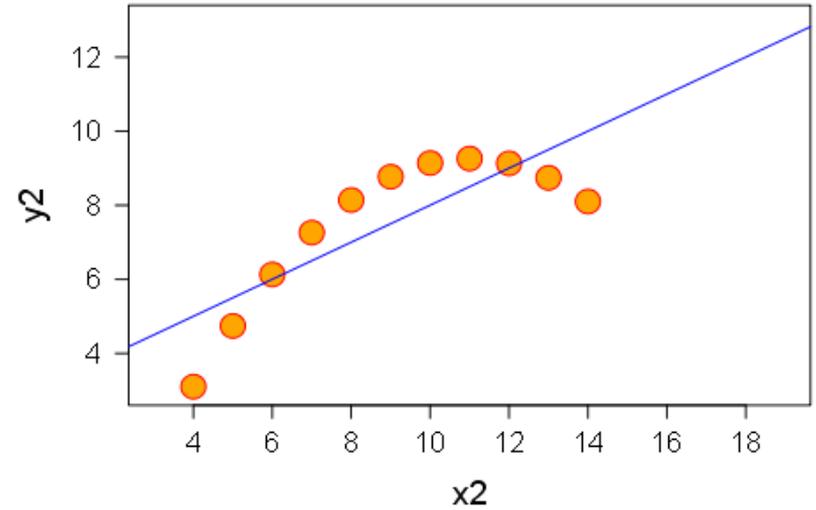
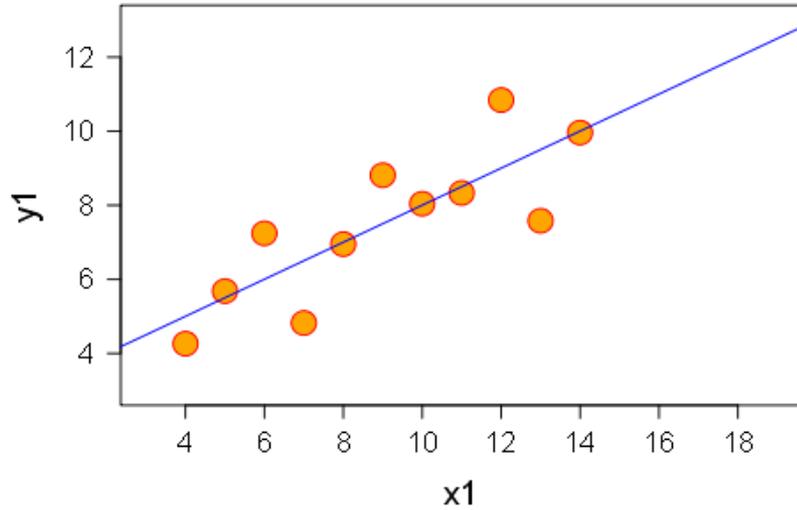
**Korreliert heisst nicht  
notwendigerweise kausal  
verknüpft(!)**



Beispiele:



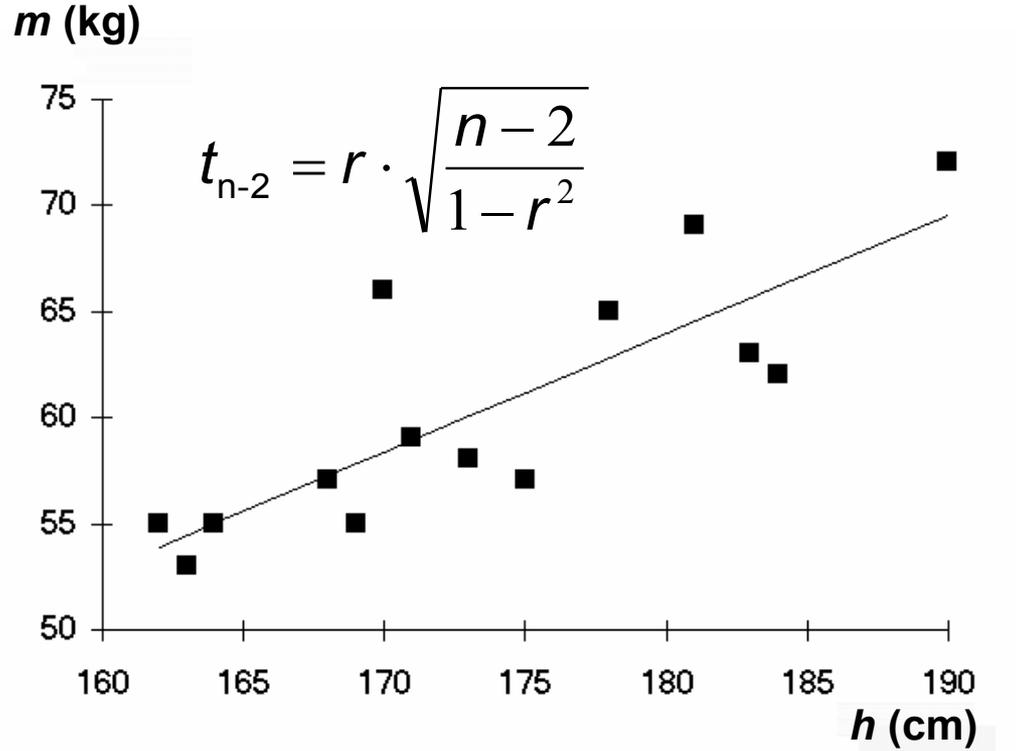
# Extrembeispiel: $r=0.816$ , $y = 3 + 0.5x$ (Anscombe's quartet)



# t-Test zur Korrelationsanalyse

Gibt es eine Beziehung zw. der Körpergröße und Gewicht?

Körperhöhe (cm)	Gewicht (kg)	
162	55	53.929
163	53	54.487
164	55	55.045
168	57	57.278
169	55	57.837
170	66	58.395
171	59	58.953
173	58	60.07
175	57	61.186
178	65	62.861
181	69	64.536
183	63	65.652
184	62	66.211
190	72	69.56



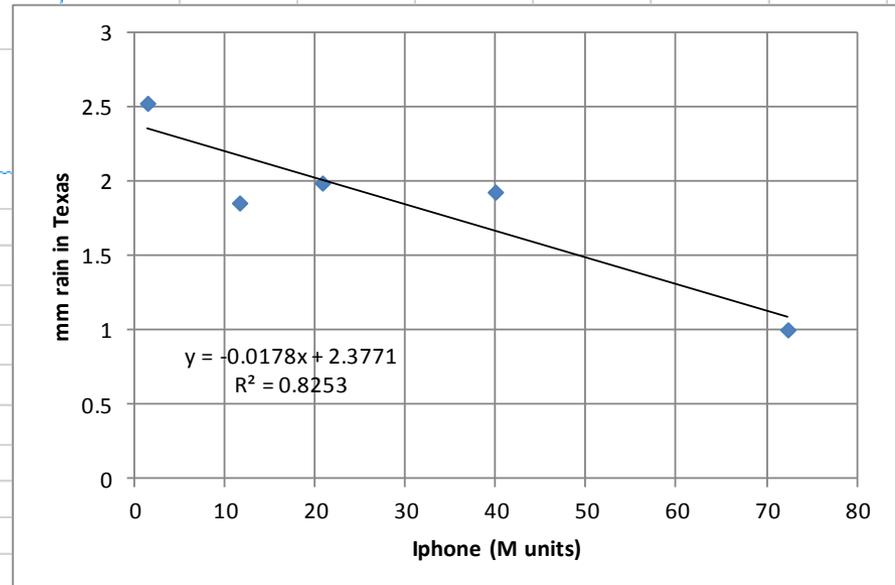
	$m =$	0.5583	-36.50955	$=b$			
		0.1131	19.66358				
	$r =$	0.818505	0.6699	3.492297			
	$n =$	14	24.358	12			
	$t =$	6.030	297.07	146.3537			

$$|t| = 6.030 > t_{12, \text{krit}(0,05)} = 2.179 \Rightarrow H_0 \text{ ist falsch (} p < 0.05 \text{)}$$

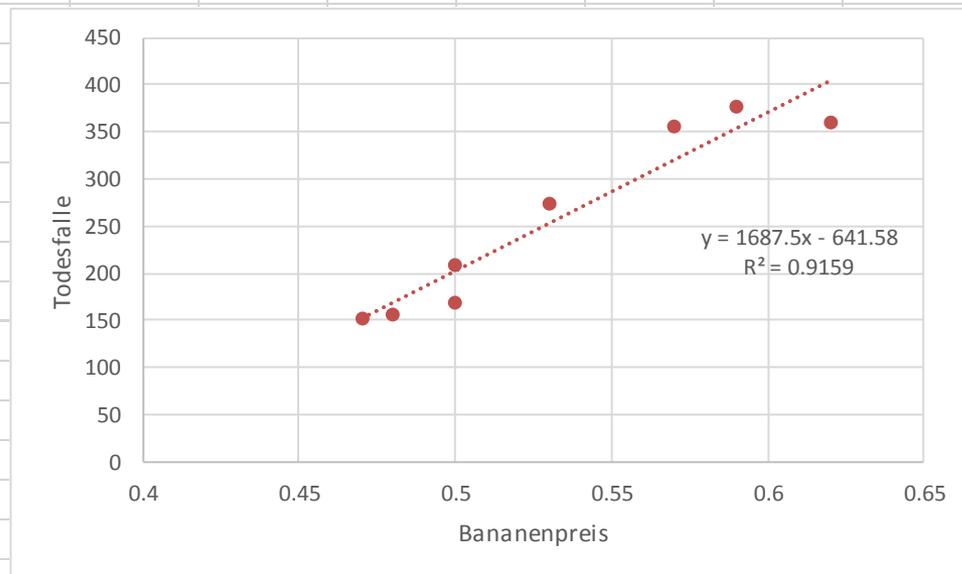
$$|t| = 6.030 > t_{12, \text{krit}(0,01)} = 3.055 \Rightarrow H_0 \text{ ist falsch (} p < 0.01 \text{)}$$

# Korrelation heisst noch lange nicht Ursache!!!

	<u>2007</u>	<u>2008</u>	<u>2009</u>	<u>2010</u>	<u>2011</u>
<b>Apple iPhone sales</b> Millions of units ( )	1.39	11.63	20.73	39.99	72.29
<b>Precipitation in Texas</b> Avg Daily Precipitation (mm) (CDC)	2.52	1.85	1.99	1.93	1
		1.39	2.52		
		11.63	1.85		
		20.73	1.99		
		39.99	1.93		
		72.29	1		
	R	-0.90846			
	n	5			
	t	-3.76471			
	P	0.032784			
		p<0.05			



	<u>1999</u>	<u>2000</u>	<u>2001</u>	<u>2002</u>	<u>2003</u>	<u>2004</u>	<u>2005</u>	<u>2006</u>
<b>Cost of bananas (unadjusted)</b>								
Dollars per pound (Bureau of Labor)	0.5	0.47	0.48	0.5	0.53	0.62	0.57	0.59
<b>People who died by falling out of their wheelchair</b>								
Deaths (US) (CDC)	169	154	157	209	274	360	356	377

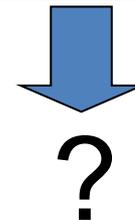


# Kontingenztabellen. Chi-Quadrat-Test



Beispiel 1

	mit Brille	ohne Brille	Total
Frau	28	75	103
Mann	48	49	97
	76	124	200



# Korrelationsanalyse zwischen kategorischen Merkmalen

Häufigkeitstabelle (Kontingenztafel):  
eine tabellarische Darstellung der gemeinsamen Häufigkeitsverteilung zweier Variablen  $X$  (z.B. Geschlecht) und  $Y$  (Brillenträgerschaft)

	mit Brille	ohne Brille	Total
Frau	a=28	b=75	103
Mann	c=48	d=49	97
	76	124	200

**Frage:** unterscheidet sich die Häufigkeit eines feststellbaren Merkmals (Symptoms) in zwei Populationen?

## Aufstellung der Nullhypothese

$H_0$ : Geschlecht und Brillenträgerschaft sind voneinander **unabhängig** (es gibt keinen Unterschied)

$$\frac{a'}{b'} = \frac{c'}{d'} \quad \text{oder} \quad \frac{a'}{c'} = \frac{b'}{d'}$$

Wie gross wäre die **erwartete Häufigkeit** (expected frequency) in der Zelle  $a'$ , wenn die Nullhypothese gültig ist?

Anzahl der Frauen:

$$a + b = 103$$

Anzahl der Personen mit Brille:

$$a + c = 76$$

Proportion der Frauen in der Stichprobe:

$$P(\text{Frau}) = (a + b)/n = 103/200$$

Proportion der Personen mit Brille:

$$P(\text{mit Brille}) = (a + c)/n = 76/200$$

	mit Brille	ohne Brille	Total
Frau	$a'=?$	$b'=?$	103
Mann	$c'=?$	$d'=?$	97
	76	124	200

erwartete (expected)  
Kreuztabelle

**Erwartete Häufigkeiten.** Annahme:  $H_0$  ist gültig  $\Rightarrow$   
Geschlecht und Brillenträgerschaft sind unabhängige Ereignisse

erwartete Häufigkeit in der Zelle links oben:  $a' = \frac{a+b}{n} \cdot \frac{a+c}{n} \cdot n = \frac{(a+b) \cdot (a+c)}{n}$

erwartete Häufigkeit in der Zelle rechts oben:  $b' = \frac{a+b}{n} \cdot \frac{b+d}{n} \cdot n = \frac{(a+b) \cdot (b+d)}{n}$

erwartete Häufigkeit in der Zelle links unten:  $c' = \frac{c+d}{n} \cdot \frac{a+c}{n} \cdot n = \frac{(c+d) \cdot (a+c)}{n}$

erwartete Häufigkeit in der Zelle rechts unten:  $d' = \frac{c+d}{n} \cdot \frac{b+d}{n} \cdot n = \frac{(c+d) \cdot (b+d)}{n}$

	mit	ohne	Total
F	a=28	b=75	103
M	c=48	d=49	97
	76	124	200

empirische (observierte,  
observed) Kreuztabelle

	mit	ohne	Total
F	$103 \cdot 76 / 200$	$103 \cdot 124 / 200$	103
M	$97 \cdot 76 / 200$	$97 \cdot 124 / 200$	97
	76	124	200

erwartete (expected)  
Kreuztabelle

## Die erwartete Häufigkeiten aus der empirischen Häufigkeiten

	mit	ohne	Total
F	a=28	b=75	103
M	c=48	d=49	97
	76	124	200

empirische (observed)  
Kreuztabelle

	mit	ohne	Total
F	a'=39.14	b'=63.86	103
M	c'=36.86	d'=60.14	97
	76	124	200

erwartete (expected)  
Kreuztabelle

$$(\text{erwartete Häufigkeit}) = \frac{(\text{Spaltensumme}) \cdot (\text{Zeilensumme})}{(\text{Anzahl der Daten in der Stichprobe})}$$

Wenn die Nullhypothese ist gültig:

Die Werte in der entsprechenden Zellen der Kontingenztafeln mit empirischen und erwarteten Häufigkeiten sind ungefähr gleich.

Die folgende Prüfgrösse (gewichtete quadratische Summe) zeigt **Chi-quadrat Verteilung**:

**Prüfgrösse**

$$\chi^2 = \sum_i \frac{(O_i - E_i)^2}{E_i},$$

wobei

$O_i$  die empirische (observed)

$E_i$  die erwartete (expected) Häufigkeit

in der  $i$ -ten Zelle sind.

**Freiheitsgrad:** (Anzahl der Zeilen  $-1$ )\*(Anzahl der Spalten  $-1$ )  
für eindimensionalen Tabellen:  $n-1$

z.B.  $2 \times 2$  (vierfelder-) Tabelle: 1

## Bedingungen der Durchführung

$n$  (Stichprobenumfang) soll genügend gross sein

In der Kontingenztabelle der *erwarteten* Häufigkeiten sollen alle Zellenwerte grösser als 1 sein.

In der Kontingenztabelle der erwarteten Häufigkeiten soll die Anzahl der Zellen, in den der Wert zwischen 1 und 5 ist, weniger als 20 % der Stichprobenumfang sein.

(z.B. Vierfeldertabelle: alle Elemente sollen grösser als 5 sein)

# Speziellfall für Vierfeldertabelle (Praktikumsbuch 2.b.30)

## Vierveldertest

	das untersuchte Merkmal		insgesamt
	ist vorhanden	ist nicht vorhanden	
Kollektiv <i>A</i>	<i>a</i>	<i>b</i>	<i>a+b</i>
Kollektiv <i>B</i>	<i>c</i>	<i>d</i>	<i>c+d</i>
insgesamt	<i>a + c</i>	<i>b + d</i>	<i>n</i>

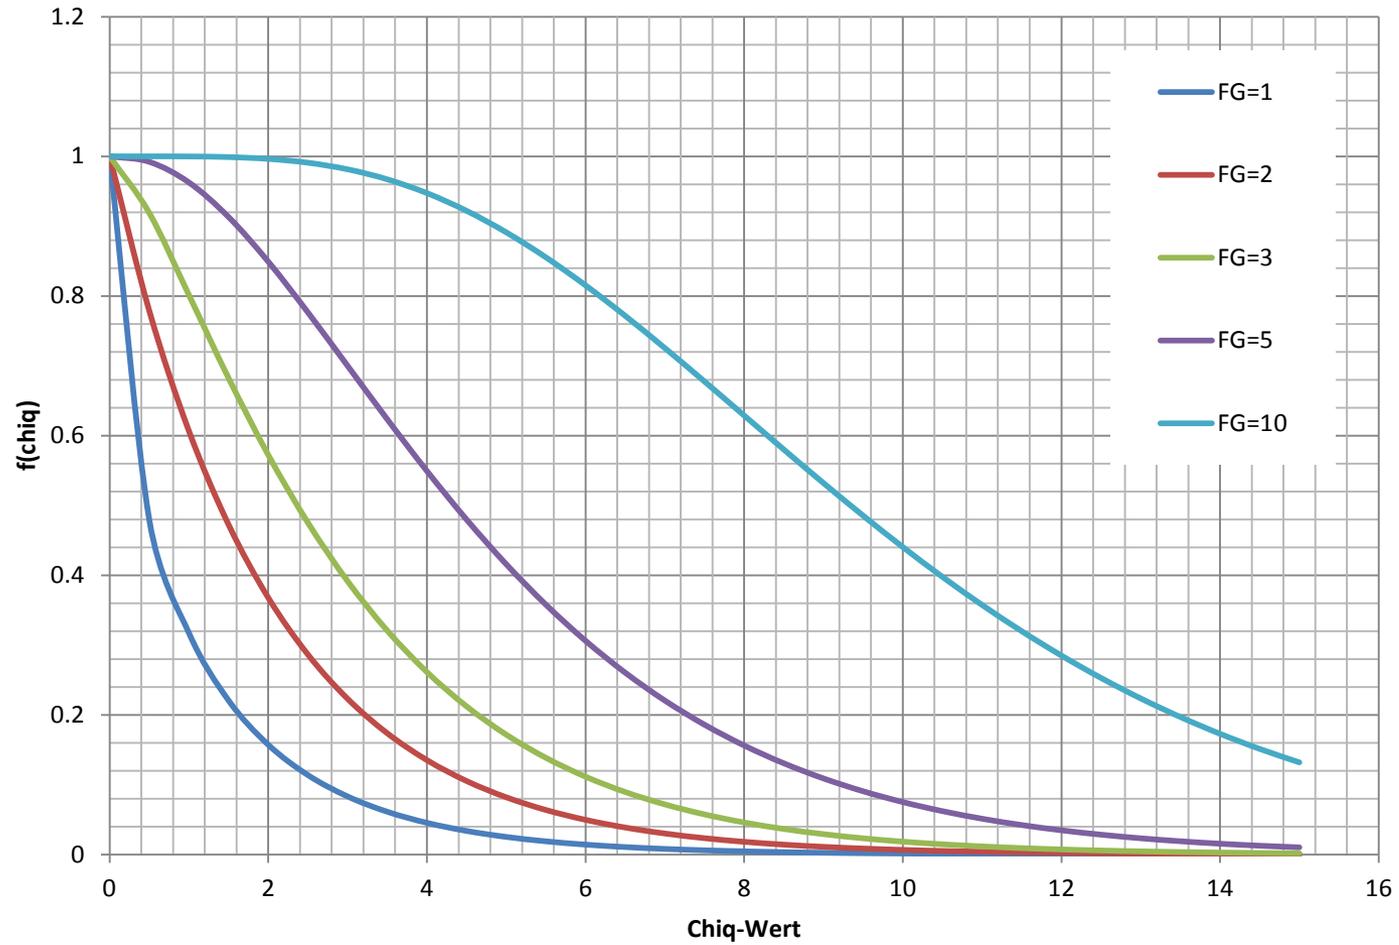
$$\chi_M^2 = \frac{n \cdot (ad - bc)^2}{(a+b)(c+d)(a+c)(b+d)}$$

### Die Bedingung der Durchführung:

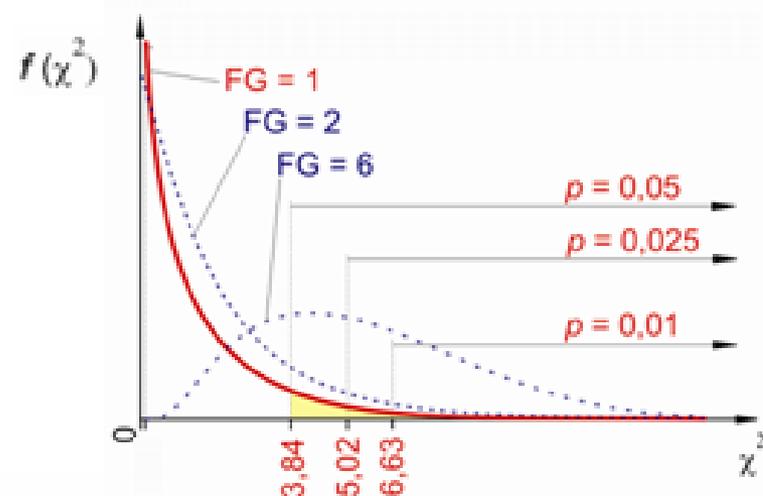
das Produkt der zwei kleinsten Teilsummen  
soll grösser sein als  $5n$

$$\frac{a}{b} = \frac{c}{d} \Leftrightarrow ad = bc$$

## Die Chiq. Verteilung ist auch eine Familie...



## $\chi^2$ (CHI-QUADRAT)-VERTEILUNG



Freiheitsgrad (FG)	$p$ (Irrtumswahrscheinlichkeit)						
	0,99	0,975	0,95		0,025	0,01	0,001
1	0,0000157	0,0000982	0,000393		5,02	6,63	10,83
2	0,0201	0,0506	0,103		7,88	9,21	13,82
3	0,115	0,216	0,352		9,35	11,34	16,27
4	0,297	0,484	0,711		11,14	13,28	18,47
5	0,554	0,831	1,15		12,83	15,09	20,51
6	0,872	1,24	1,64		14,45	16,81	22,46
7	1,24	1,69	2,17		16,01	18,47	24,32
8	1,65	2,18	2,73		17,53	20,09	26,13
9	2,16	2,70	3,34		18,96	21,92	27,88
10	2,75	3,25	4,02		20,48	23,58	29,59

## Beispiel 1

Die Bedingung des Tests:  
das Produkt der zwei kleinsten  
Teilsummen soll grösser sein als  $5n$

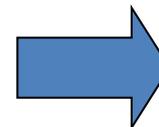
	mit Brille	ohne Brille	Total
Frau	a=28	b=75	103
Mann	c=48	d=49	97
	76	124	200

$$76 \cdot 97 = 7372 > 5 \cdot 200 = 1000$$

Man darf den Chi-  
Quadrat-Test anwenden

$$\chi_M^2 = \frac{200 \cdot (28 \cdot 49 - 48 \cdot 75)^2}{76 \cdot 124 \cdot 103 \cdot 97} = 10.54$$

$$10.54 > \chi_{\text{krit}}^2 = 3,84 \quad H_0 \text{ ist falsch}$$



Es gibt einen  
Zusammenhang zw.  
dem Geschlecht  
und der  
Brillenträgerschaft  
(Männer tragen  
Brille öfter)

	$p$ (Irrtumswahrscheinlichkeit)						
Freiheits- grad (FG)	0,99	0,975	0,95	0,05	0,025	0,01	0,001
1	0,0000157	0,0000982	0,000393	3,84	5,02	6,63	10,83

$$\chi_M^2 = \frac{200 \cdot (28 \cdot 49 - 48 \cdot 75)^2}{76 \cdot 124 \cdot 103 \cdot 97} = 10.54$$

$$10.54 > \chi_{\text{krit}}^2 = 3.84 \quad H_0 \text{ ist falsch}$$

$$10.54 > \chi_{\text{krit}}^2 = 6.63 \quad H_0 \text{ ist falsch}$$

**mit einem Signifikanzniveau: <0.01**

	A	B	C	D
1	<b>Empirische Werte</b>			
2		mit Brille	ohne Brille	
3	Frau	28	75	=SUMME(B3:C3)
4	Mann	48	49	=SUMME(B4:C4)
5		=SUMME(B3:B4)	=SUMME(C3:C4)	=SUMME(B5:C5)
6				
7	<b>Ewartete Werte</b>			
8		mit Brille	ohne Brille	
9	Frau	=D3*B5/D5	=D3*C5/D5	=SUMME(B9:C9)
10	Mann	=D4*B5/D5	=D4*C5/D5	=SUMME(B10:C10)
11		=SUMME(B9:B10)	=SUMME(C9:C10)	=SUMME(B11:C11)
12				
13			Signifikanzniveau:	=CHITEST(B3:C4,B9:C10)
14			Chi <sup>2</sup> -Wert:	=CHIINV(D13,1)

	A	B	C	D
1	<b>Empirische Werte</b>			
2		mit Brille	ohne Brille	
3	Frau	28	75	103
4	Mann	48	49	97
5		76	124	200
6				
7	<b>Ewartete Werte</b>			
8		mit Brille	ohne Brille	
9	Frau	39.140	63.860	103
10	Mann	36.860	60.140	97
11		76	124	200
12				
13			Signifikanzniveau:	0.0012
14			Chi <sup>2</sup> -Wert:	10.5442606

## Kalkulation mit Excel

## Beispiel 2



	mit Brille	ohne Brille	Total
Frau	1	3	4
Mann	5	3	8
	6	6	12



$$4 \cdot 6 = 24 < 5 \cdot 12 = 60$$

Dürfen wir in diesem Fall den Chi-Quadrat-Test nicht anwenden.



# Erhöhung des Umfanges der Stichprobe



	mit	ohne	Total
F	1	3	4
M	5	3	8
	6	6	12

12 → 200

	mit	ohne	Total
F	28	75	103
M	48	49	97
	76	124	200

$$\frac{n_{\text{mit}}}{n_{\text{ohne}}} = \frac{1}{3} = 0.33$$

Frauen

$$\frac{n_{\text{mit}}}{n_{\text{ohne}}} = \frac{28}{75} = 0.37$$

$$\frac{n_{\text{mit}}}{n_{\text{ohne}}} = \frac{5}{3} = 1.67$$

Männer

$$\frac{n_{\text{mit}}}{n_{\text{ohne}}} = \frac{48}{49} = 0.98$$

es gibt eine Vermutung, aber  
der Nachweis geht nicht

$n$  vergrößert sich (12 → 200):  
der Nachweis geht

**Beispiel 3**  $H_0$ : die Häufigkeit von Lungenkrebs bei Rauchern und Nichtrauchern ist identisch, d.h.  $\chi^2 = 0$ .

$H_1$ : die beiden Häufigkeiten unterscheiden sich, also ist  $\chi^2 \neq 0$ .

In der Tabelle sind die Häufigkeiten der zwei Kollektive aus der Stichprobe einer Lungenfürsorge dargestellt.

Da  $23 \cdot 27 = 621 > 5 \cdot 61 = 305$ , kann der Test durchgeführt werden.

$$\chi_M^2 = \frac{61 \cdot (14 \cdot 25 - 9 \cdot 13)^2}{23 \cdot 38 \cdot 34 \cdot 27} = 4.13$$

Es ist zu sehen, dass  $\chi_M^2 \neq 0$

ist, aber ist der Unterschied auch signifikant (oder nur zufällig)?

	Lungenkrebs	kein Lungenkrebs	
Raucher	14	13	27
Nichtraucher	9	25	34
	23	38	61

Sei das Signifikanzniveau: 5%.

Der Freiheitsgrad (2x2 Tabelle) ist: 1.

$4.13 > \chi_{\text{krit}}^2 = 3,84 \rightarrow H_0$  ist falsch

Danach ist der Unterschied in der Häufigkeit von Lungenkrebs bei Rauchern und Nicht-rauchern signifikant (bei einem Signifikanzniveau von 5%).

**Beispiel 4** (Pr. Buch, R.103.) Über eine erfolgreiche operative Korrektur einer bestimmten Augenkrankheit (ischaemische optische Neuropathie vom nicht-arterialen Typ) wurde im Jahre 1989 eine Veröffentlichung ausgegeben. Da in dieser Krankheit früher keinerlei wirksame Behandlungsmethode bekannt war, wurde dieser Eingriff verbreitet angewendet. Kürzlich erschienen jedoch Berichte auch von erfolglosen Eingriffen, daher hat man 244 solche Kranken in 25 klinischen Zentren statistisch erfasst, von denen bei 119 Personen die Operation durchgeführt wurde, bei 125 Kranken jedoch nicht. Die Beobachtungen in tabellarischer Form:

empirische Häufigkeiten

	operiert	nicht op.	insg.
verbessert	39	53	92
nicht verbessert	52	56	108
verschlechtert	28	16	44
insgesamt	119	125	244

erwartete Häufigkeiten

	operiert	nicht op.	insg.
verbessert	45	47	92
nicht verbessert	53	55	108
verschlechtert	21	23	44
insgesamt	119	125	244

Es ist mit statistischen Methoden zu prüfen, ob die Anzahl der Besserungen ohne Operation tatsächlich höher war?  $H_0$ : keine Differenz

$$\chi^2 = \frac{(39-44.87)^2}{44.87} + \frac{(53-47.13)^2}{47.13} + \frac{(52-52.67)^2}{52.67} + \frac{(56-55.33)^2}{55.33} + \frac{(28-21.46)^2}{21.46} + \frac{(16-22.54)^2}{22.54} = 5.407$$

Weil  $5.407 < 5.991 = \chi^2_{\text{krit, FG=2}}$ , ablehnen wir die  $H_0$  nicht.

Wieder ist alles im Excel einfacher:

empirische Häufigkeiten

	operiert	nicht op.	insg.
verbessert	39	53	92
nicht verbessert	52	56	108
verschlechtert	28	16	44
insgesamt	119	125	244

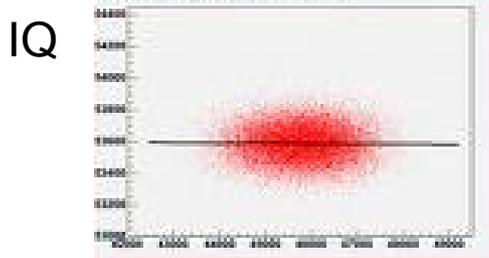
erwartete Häufigkeiten

	operiert	nicht op.	insg.
verbessert	45	47	92
nicht verbessert	53	55	108
verschlechtert	21	23	44
insgesamt	119	125	244

$P = \text{chisq.test}(\text{beobachtet}; \text{erwartet})$

# Arten von Abhängigkeitsbeziehungen

Unabhängigkeit



Körpergröße

Abhängigkeit

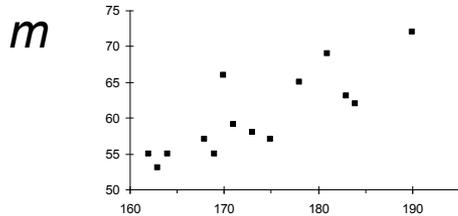
stochastische  
Beziehung

deterministische  
Beziehung

Korrelations-  
analyse

vermischt

Assoziations-  
analyse

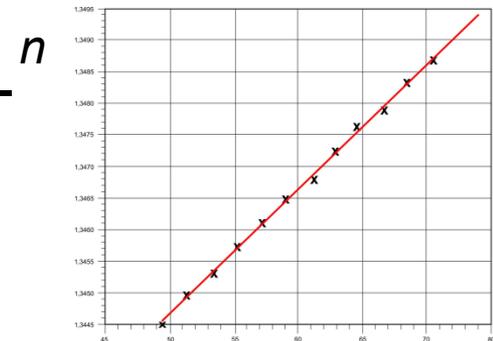


Körpergröße

Geschmack



Färbung



Konzentration

numerisch

ordinal

nominal

numerisch