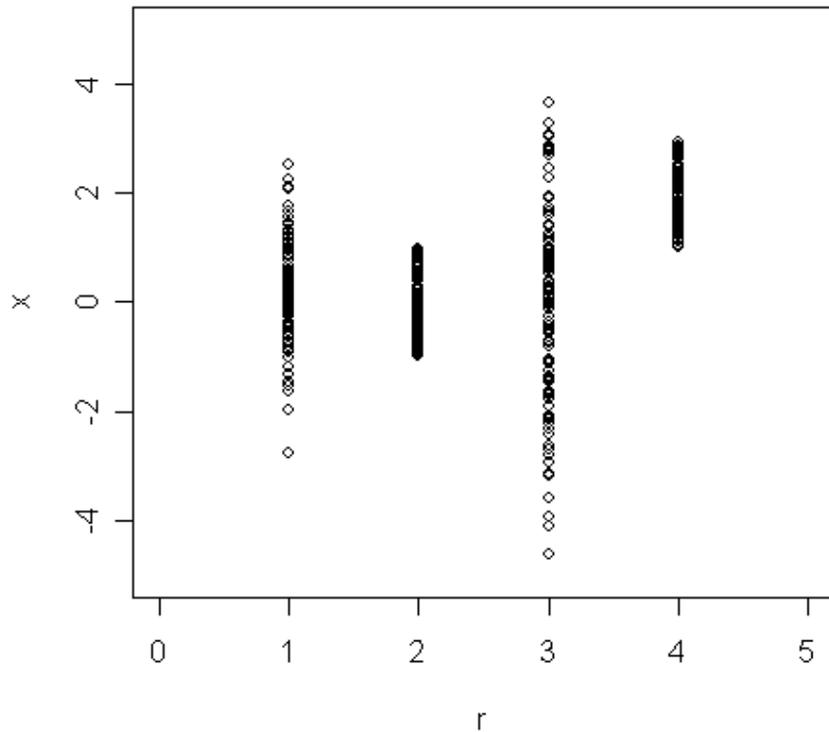


# Wirtschaftsstatistik

Claudia Redenbach

SS 2010

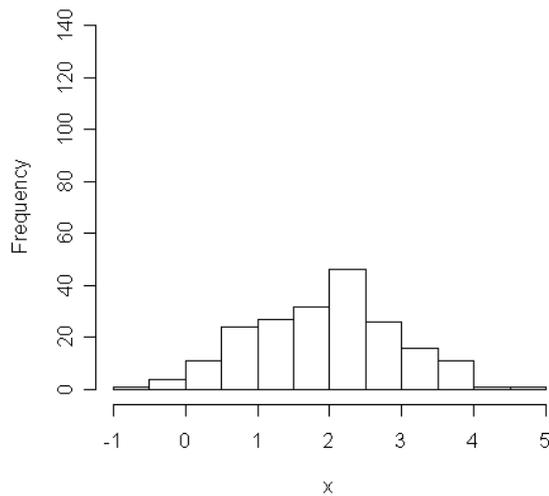
# Lagemaßzahlen



	$x_n$	$x_{med}$
1	0.15	0.19
2	0.00	0.00
3	-0.08	0.10
4	1.98	1.99

# Verteilungstypen

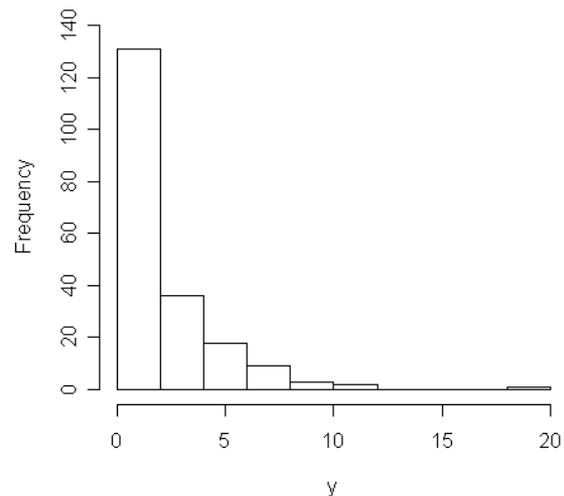
## Symmetrisch



$$x_{\text{med}}=2.01$$

$$x_n = 1.91$$

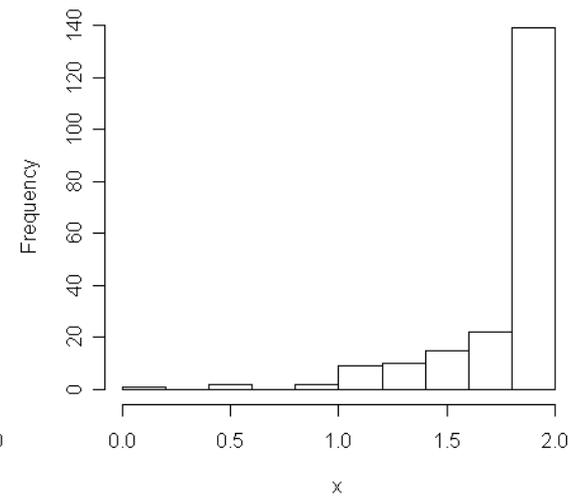
## Linkssteil



$$x_{\text{med}}=1.07$$

$$x_n = 1.99$$

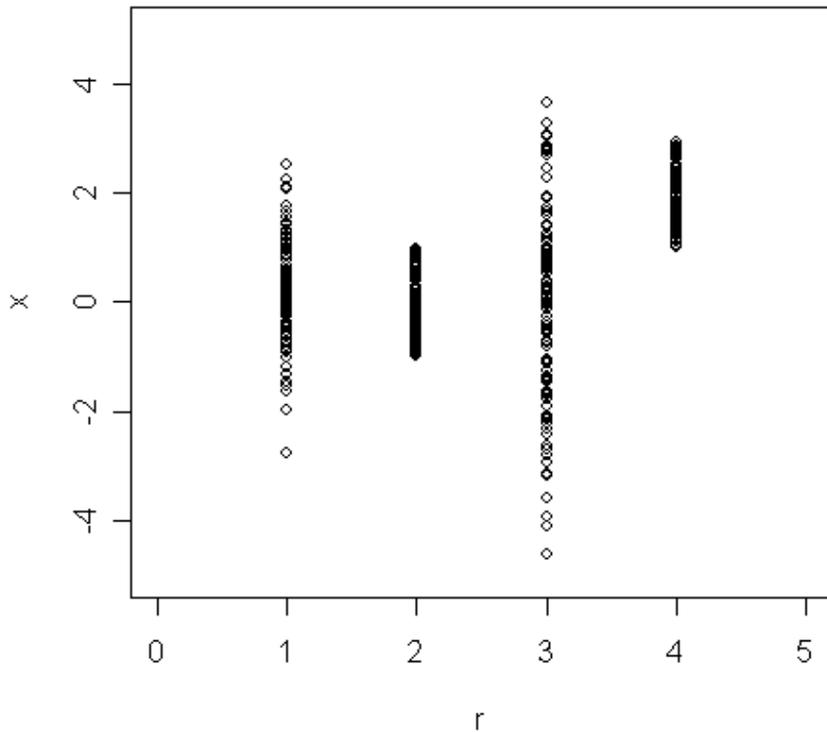
## Rechtssteil



$$x_{\text{med}}=1.91$$

$$x_n = 1.78$$

# Streuung



	$x_n$	$x_{\text{med}}$
1	0.15	0.19
2	0.00	0.00
3	-0.08	0.10
4	1.98	1.99

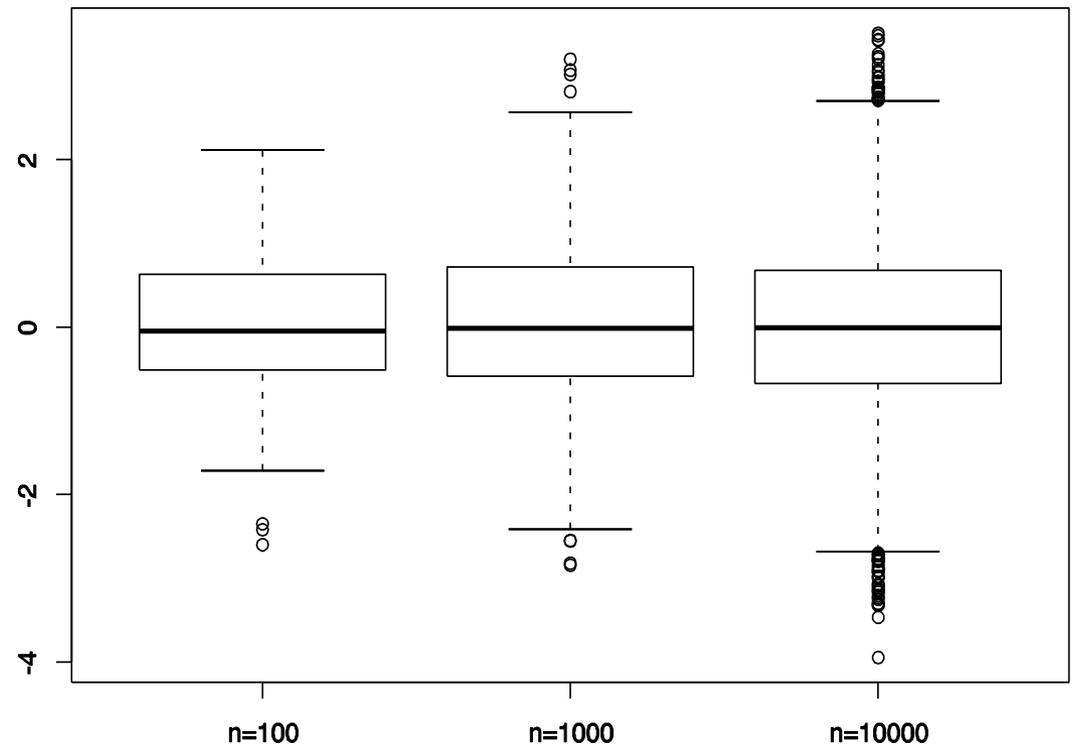
	$s_n^2$	$(s_n^2)^{0.5}$
1	0.86	0.93
2	0.38	0.61
3	3.51	1.87
4	0.32	0.57

# Zur Berechnung von Quantilen

- Beispiel: Autounfälle in einer Stadt pro Tag
- $n=14$   
20,17,22,21,26,45,25,18,23,25,15,24,30,26
- $z_{0.25}$ :  $14 \cdot 0.25 = 3.5$ , also  $z_{0.25} = x_{(4)} = 20$
- $z_{0.75}$ :  $14 \cdot 0.75 = 10.5$ , also  $z_{0.75} = x_{(11)} = 26$
- Beachte:  
Die R-Funktion `quantile()` implementiert eine gegenüber der Vorlesung veränderte Definition der Quantile.  
Sie liefert hier  $z_{0.25} = 20.25$  und  $z_{0.75} = 25.75$

# Boxplots

- Strich: Median
- Box: Quartile
- Whisker: 5% - und 95%-Quantile der Daten
- Kreise: Ausreißer
  
- Ablesbar:  
Wertebereich,  
Symmetrie

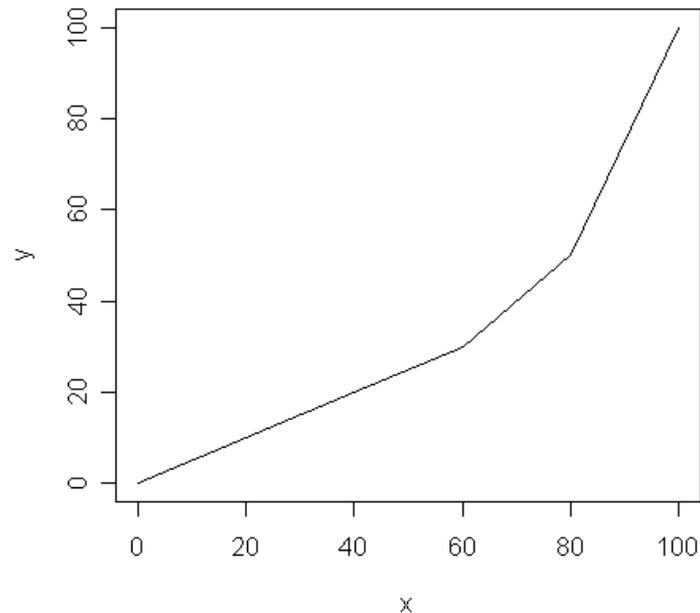


Berechnung der Whisker in R:  
Extremster Datenpunkt, der nicht weiter als  
der 1.5-fache Abstand zwischen den  
Quartilen von der Box entfernt ist.

# Lorenzkurve

Fünf Unternehmen einer Branche

Marktanteile: (10%, 10%, 10%, 20%, 50%)



# Lorenzkurve

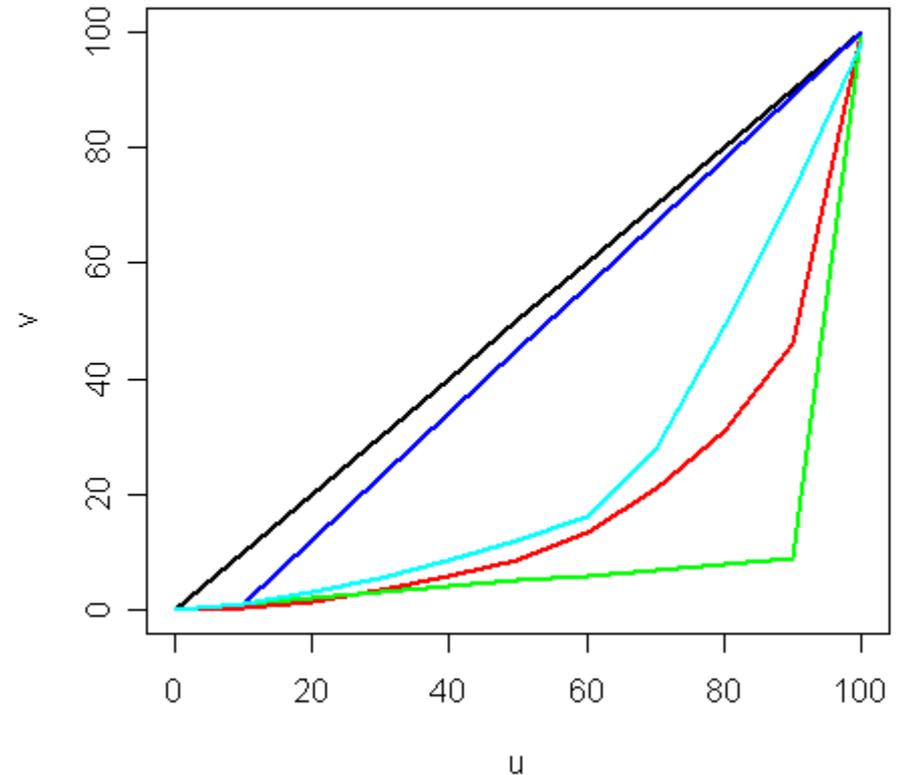
- $n=10$ , Gesamtmerkmalssumme = 10

9 x 0.1, 1 x 9.1

1 x 0.1, 9 x 1.1

(0.05, 0.1, 0.2, 0.25, 0.25,  
0.5, 0.75, 1, 1.5, 5.4)

(0.1, 0.2, 0.25, 0.3, 0.35,  
0.4, 1.2, 2.1, 2.3, 2.6)



# Gini-Koeffizient

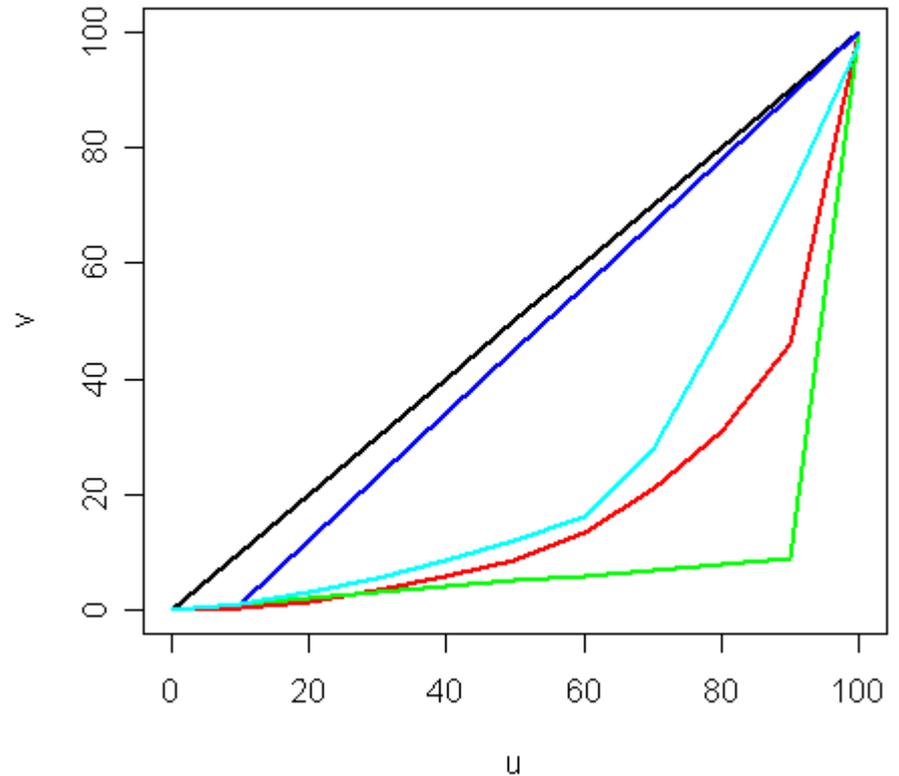
- $n=10$ , Gesamtmerkmalssumme = 10

$$\gamma = 0.81, \gamma^* = 0.9$$

$$\gamma = 0.09, \gamma^* = 0.1$$

$$\gamma = 0.64, \gamma^* = 0.71$$

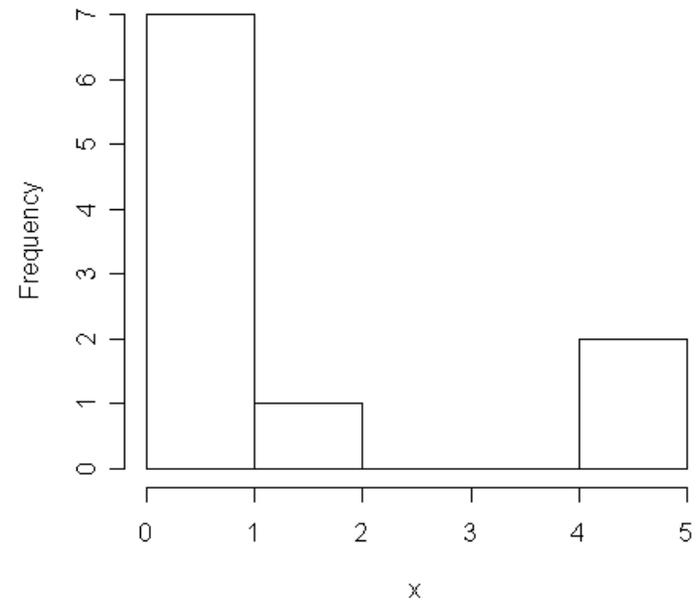
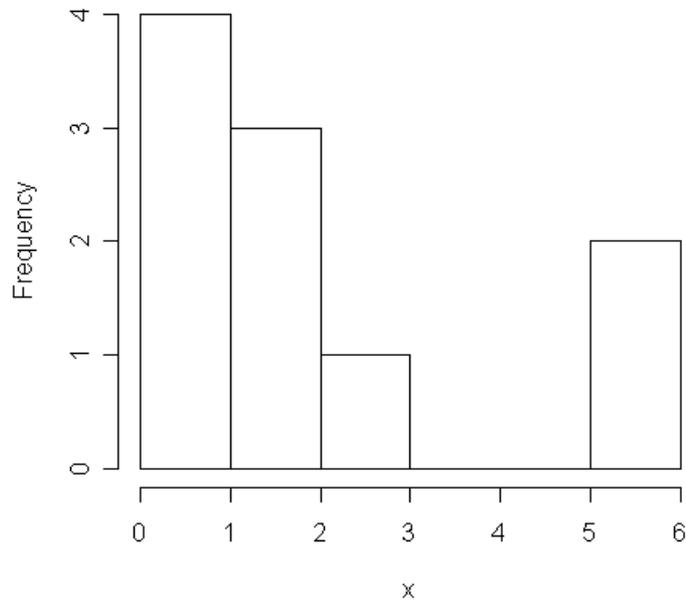
$$\gamma = 0.47, \gamma^* = 0.52$$



# Histogramm

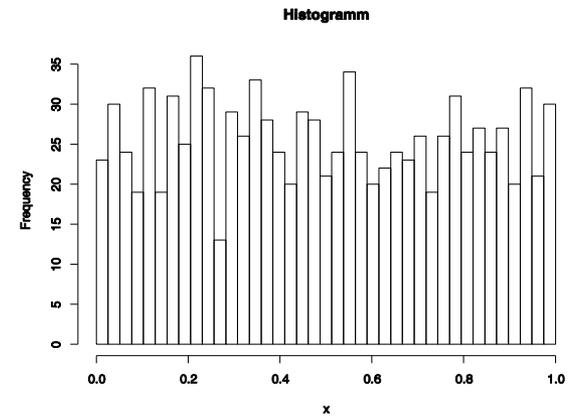
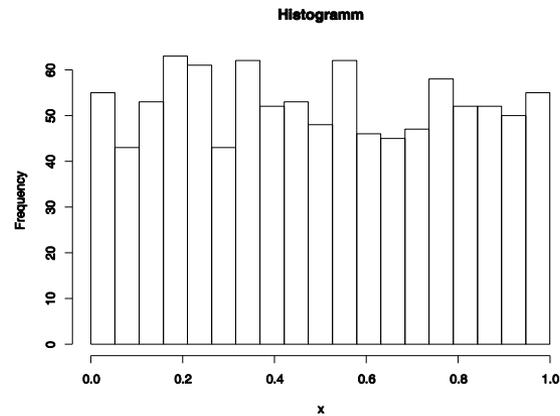
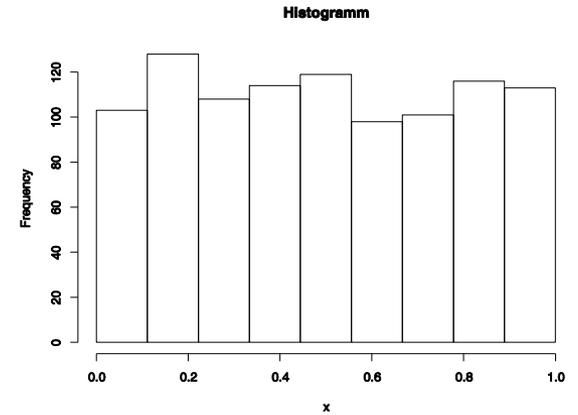
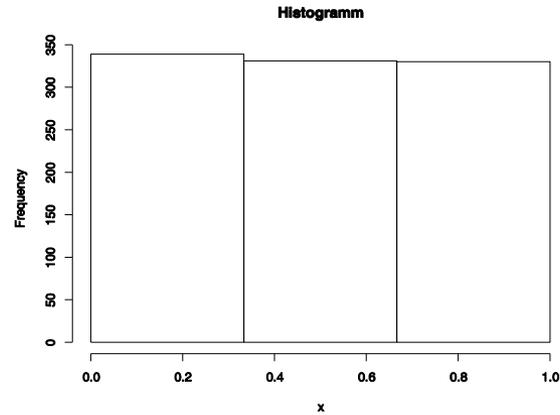
- Zähne

Beachte: R wählt standardmäßig linksoffene Intervalle (Plot rechts) . Die Option `right = F` liefert den Plot links.



# Wahl der Grenzen

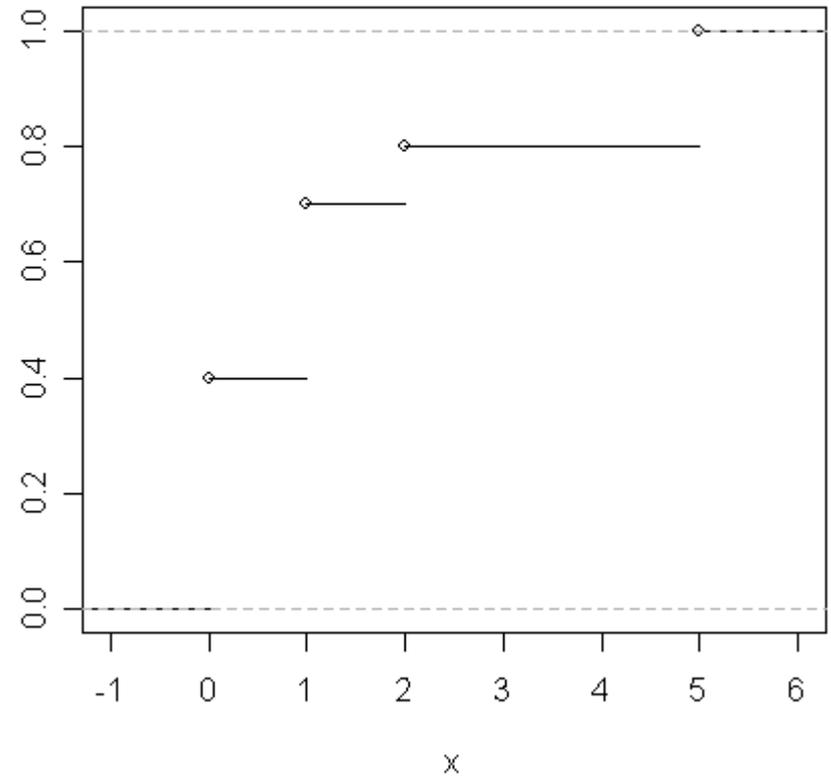
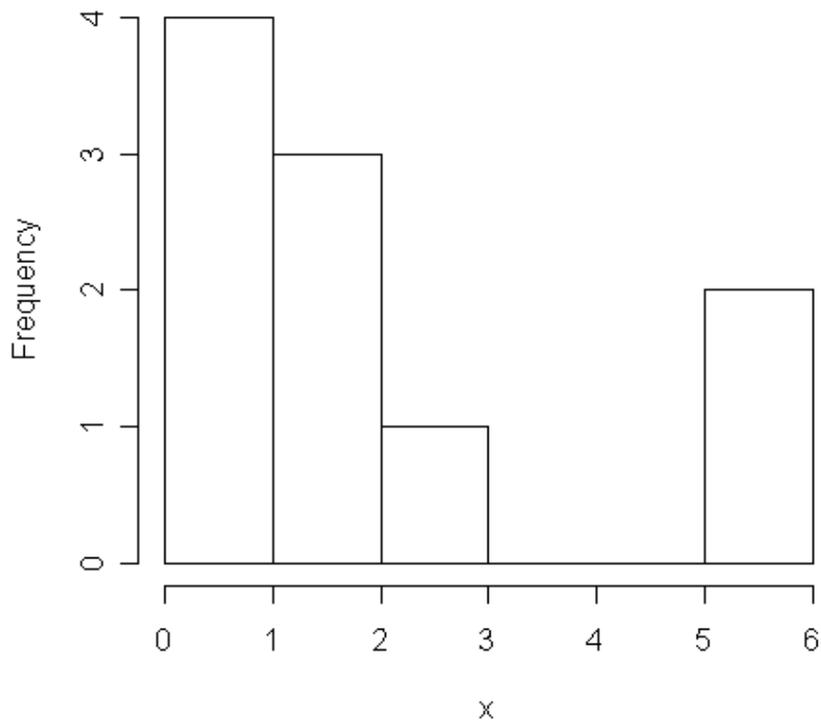
- $X_i \sim U(0,1)$
- $n=1000$



- Gleiche Realisierung in allen 4 Plots

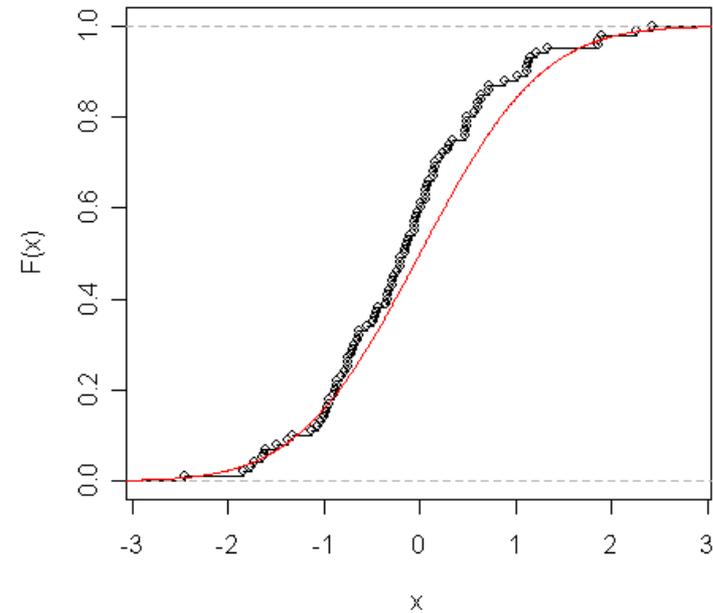
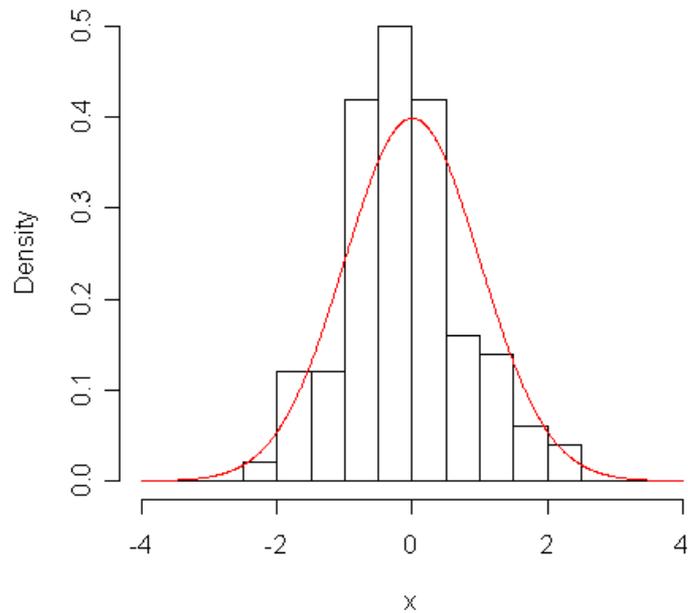
# Empirische Verteilungsfunktion

- Zähne



# Normalverteilte Daten

- $X_i \sim N(0,1)$ ,  $n = 100$



# Kontingenztafel (absolut)

- $n = 447$  männliche deutsche Arbeitslose
- X: Ausbildungsniveau: keine Ausbildung, Lehre, fachspezifische Ausbildung, Hochschulabschluss
- Y: Dauer der Arbeitslosigkeit:  $\leq 6$  Monate, 7-12 Monate,  $> 12$  Monate

	$\leq 6$	7-12	$>12$	
keine Ausbildung	86	19	18	123
Lehre	170	43	20	233
fachspezifische Ausbildung	40	11	5	56
Hochschulabschluss	28	4	3	35
	324	77	46	447

# Kontingenztafel (relativ)

- n = 447 männliche deutsche Arbeitslose
- X: Ausbildungsniveau: keine Ausbildung, Lehre, fachspezifische Ausbildung, Hochschulabschluss
- Y: Dauer der Arbeitslosigkeit:  $\leq 6$  Monate, 7-12 Monate,  $> 12$  Monate

	$\leq 6$	7-12	$>12$	
keine Ausbildung	0.192	0.043	0.040	0.275
Lehre	0.380	0.096	0.045	0.521
fachspezifische Ausbildung	0.089	0.025	0.011	0.125
Hochschulabschluss	0.063	0.009	0.007	0.078
	0.725	0.172	0.103	1

# Kontingenztafel (bedingt)

- $n = 447$  männliche deutsche Arbeitslose
- X: Ausbildungsniveau: keine Ausbildung, Lehre, fachspezifische Ausbildung, Hochschulabschluss
- Y: Dauer der Arbeitslosigkeit:  $\leq 6$  Monate, 7-12 Monate,  $> 12$  Monate
- Relative bedingte Häufigkeiten  $f_Y(\cdot | i)$

	$\leq 6$	7-12	$>12$	
keine Ausbildung	0.699	0.154	0.147	1
Lehre	0.730	0.184	0.086	1
fachspezifische Ausbildung	0.714	0.197	0.089	1
Hochschulabschluss	0.800	0.114	0.086	1

# Kontingenzkoeffizient

n = 100 männliche deutsche Arbeitslose

X: Ausbildungsniveau:  
keine Ausbildung, Lehre

Y: Dauer der Arbeitslosigkeit:  
7-12 Monate, > 12 Monate

$$T = 2.826$$

$$T' = 0.165$$

$$T^* = 0.234$$

	d <sub>1</sub>	d <sub>2</sub>	
c <sub>1</sub>	19	18	37
c <sub>2</sub>	43	20	63
	62	38	100

# Streudiagramm

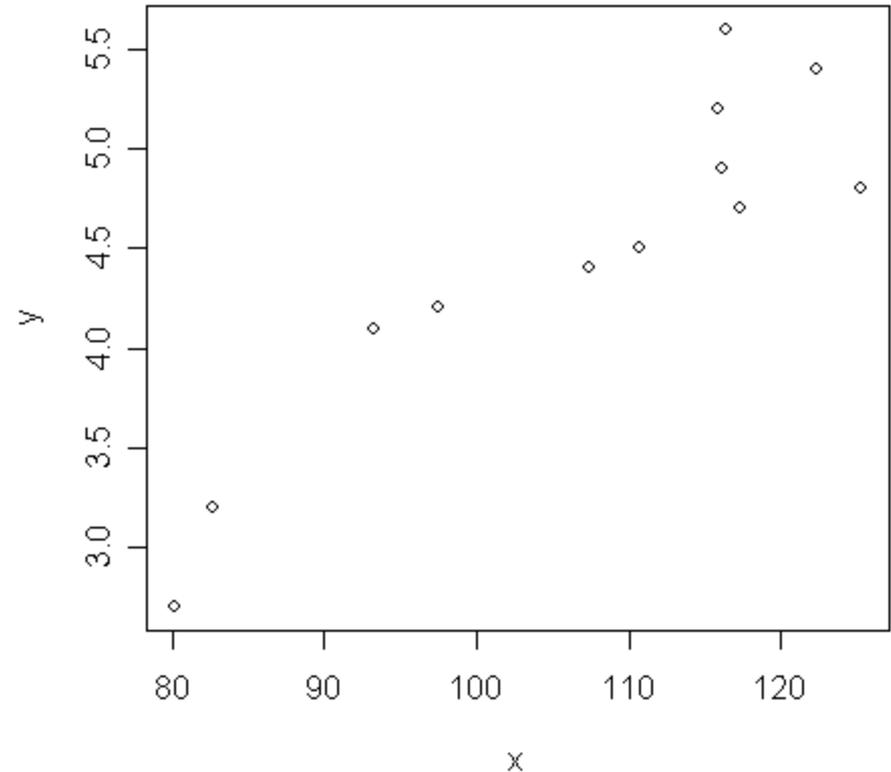
- Weinanbau im Jahr  $i$ :
- $x_i$ : mittlere Anzahl von Beeren je Traube im Juli
- $y_i$ : Ertrag in Tonnen je 100 m<sup>2</sup>

Jahr	1971	1973	1974	1975	1976	1977	1978	1979	1980	1981	1982	1983
$x_i$	116.37	82.77	110.68	97.50	115.88	80.19	125.24	116.15	117.36	93.31	107.46	122.30
$y_i$	5.6	3.2	4.5	4.2	5.2	2.7	4.8	4.9	4.7	4.1	4.4	5.4

- 1972: keine Ernte wegen Sturm

# Streudiagramm

- Weinanbau im Jahr  $i$ :
  - $x_i$ : mittlere Anzahl von Beeren je Traube im Juli
  - $y_i$ : Ertrag in Tonnen je 100 m<sup>2</sup>
  - Offenbar besteht ein Zusammenhang zwischen den Variablen X und Y:  
x groß  $\leftrightarrow$  y groß
- > Korrelationskoeffizient: 0.91

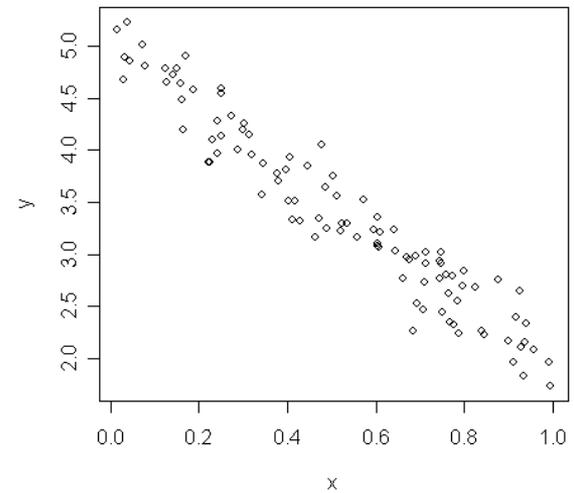
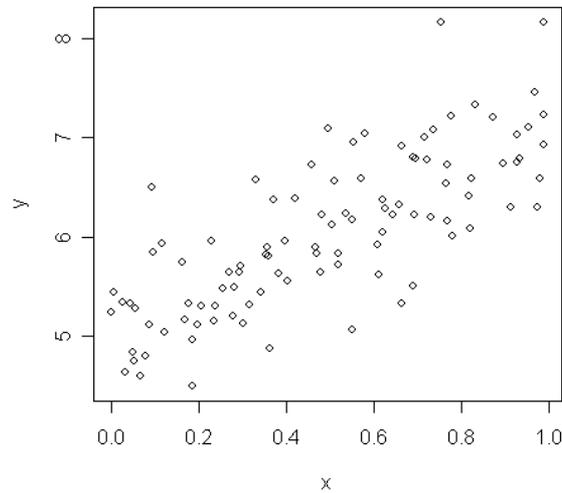
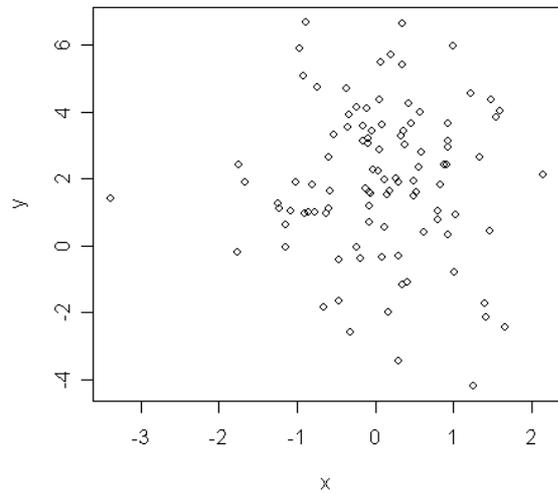


# Korrelationskoeffizient

$$\rho_{xy} = -0.025$$

$$\rho_{xy} = 0.773$$

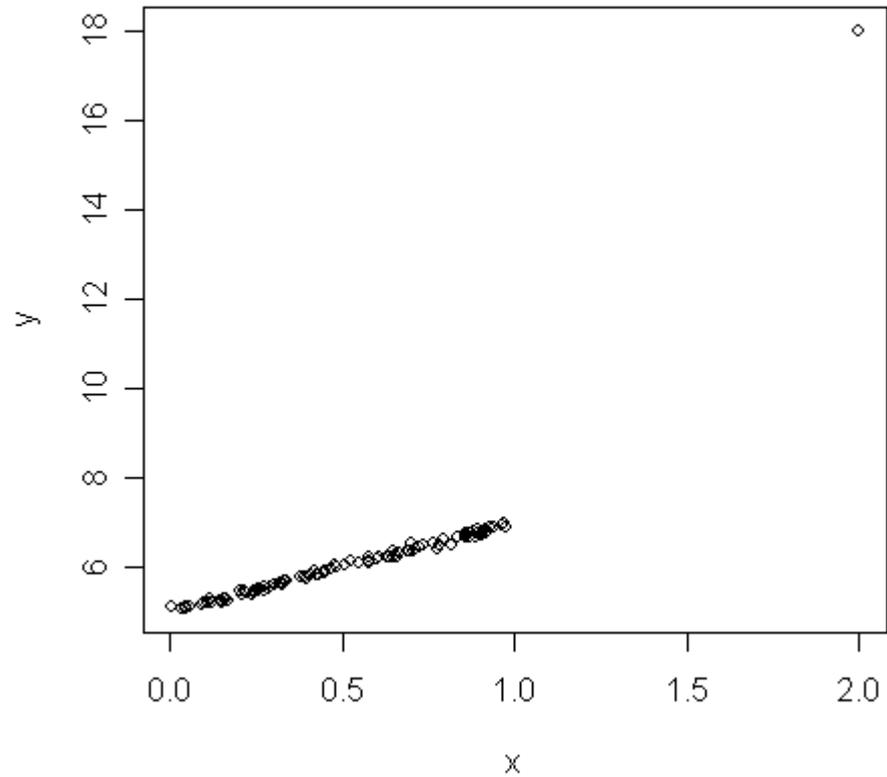
$$\rho_{xy} = -0.965$$



# Korrelationskoeffizient

$$\rho_{xy} = 0.798$$

$$\rho'_{xy} = 0.996$$



# Korrelationskoeffizient

$$\rho_{xy} = -0.025$$

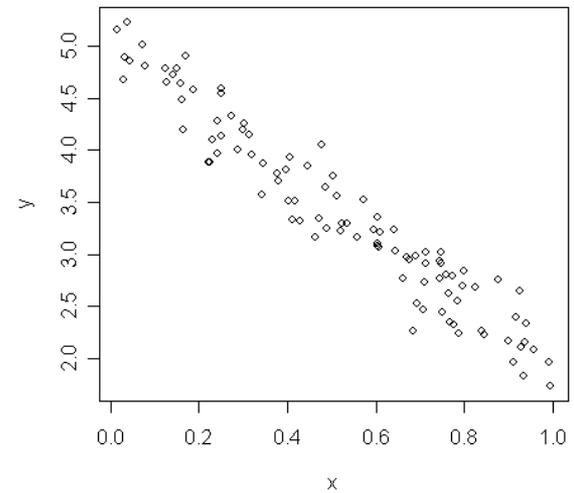
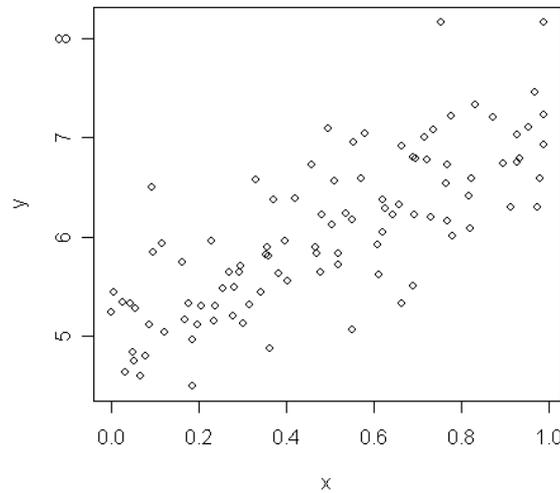
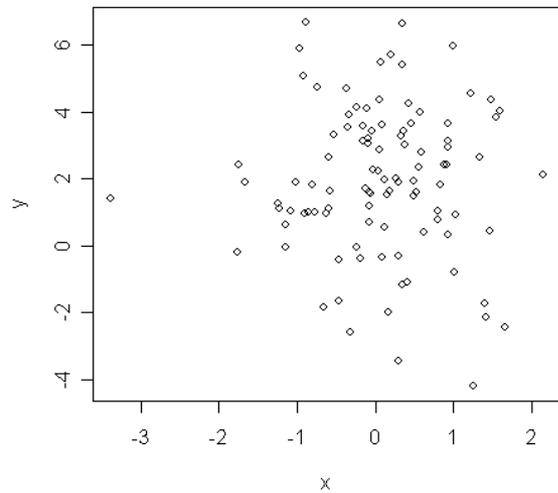
$$\rho'_{xy} = 0.033$$

$$\rho_{xy} = 0.773$$

$$\rho'_{xy} = 0.788$$

$$\rho_{xy} = -0.965$$

$$\rho'_{xy} = -0.967$$



# Beispiel: Zusammenhangsanalyse

## Daten:

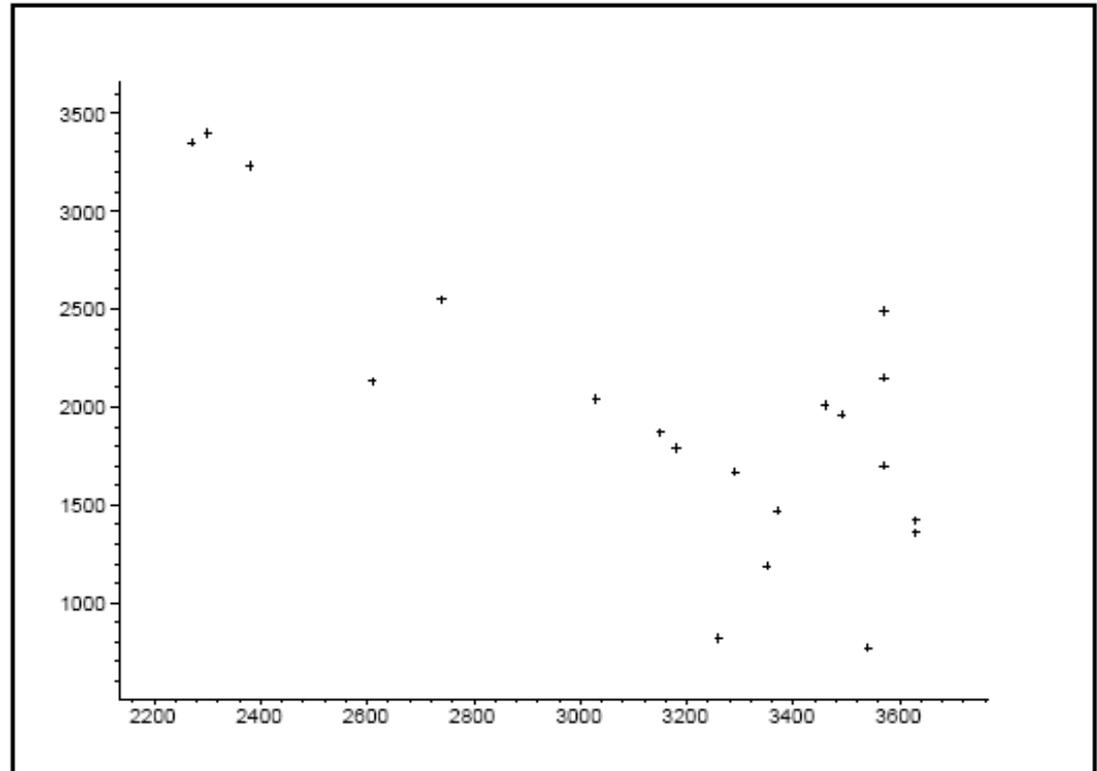
Geburtsgewicht in g von 20 Säuglingen und Gewichtszunahme in g zwischen dem 70. und 100. Tag

Säugling	Geburts- gewicht $x_i$	Gewichts- zunahme $y_i$	Säugling	Geburts- gewicht $x_i$	Gewichts- zunahme $y_i$
1	2740	2550	11	3260	820
2	3180	1790	12	3350	1190
3	3150	1870	13	3630	1360
4	3030	2040	14	3630	1420
5	3370	1470	15	3490	1960
6	2610	2130	16	3290	1670
7	3570	2150	17	3540	770
8	2270	3350	18	3570	1700
9	2300	3400	19	3460	2010
10	2380	3230	20	3570	2490

# Beispiel: Zusammenhangsanalyse

## Streudiagramm

$$\rho_{xy} = -0.762$$



# Beispiel: Zusammenhangsanalyse

Folgerungen:

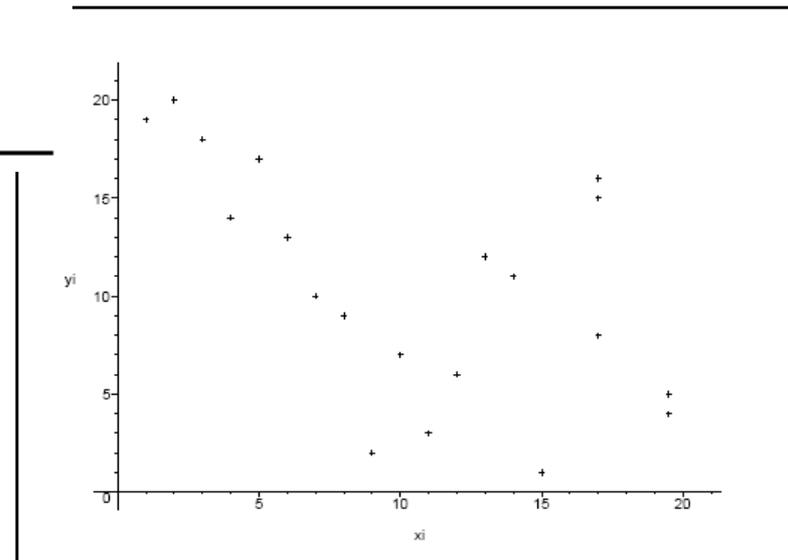
- Die beiden Merkmale sind negativ korreliert:  
kleines Geburtsgewicht -> große Zunahme
- Die Wertepaare liegen aber nicht sehr nahe an einer Geraden.
- Der lineare Eindruck entsteht vor allem durch Datensätze mit sehr geringem Geburtsgewicht.  
-> Betrachte die Ränge in dieser Stichprobe

# Beispiel: Zusammenhangsanalyse

Säugling	Rang Geb.-gewicht $rg(x_i)$	Rang Gew.-zunahme $rg(y_i)$	Säugling	Rang Geb.-gewicht $rg(x_i)$	Rang Gew.-zunahme $rg(y_i)$
1	5	17	11	9	2
2	8	9	12	11	3
3	7	10	13	19.5	4
4	6	13	14	19.5	5
5	12	6	15	14	11
6	4	14	16	10	7
7	17	15	17	15	1
8	1	19	18	17	8
9	2	20	19	13	12
10	3	18	20	17	16

$\rho'_{xy} = -0.56$  liegt näher bei 0 als  $\rho_{xy} = -0.762$

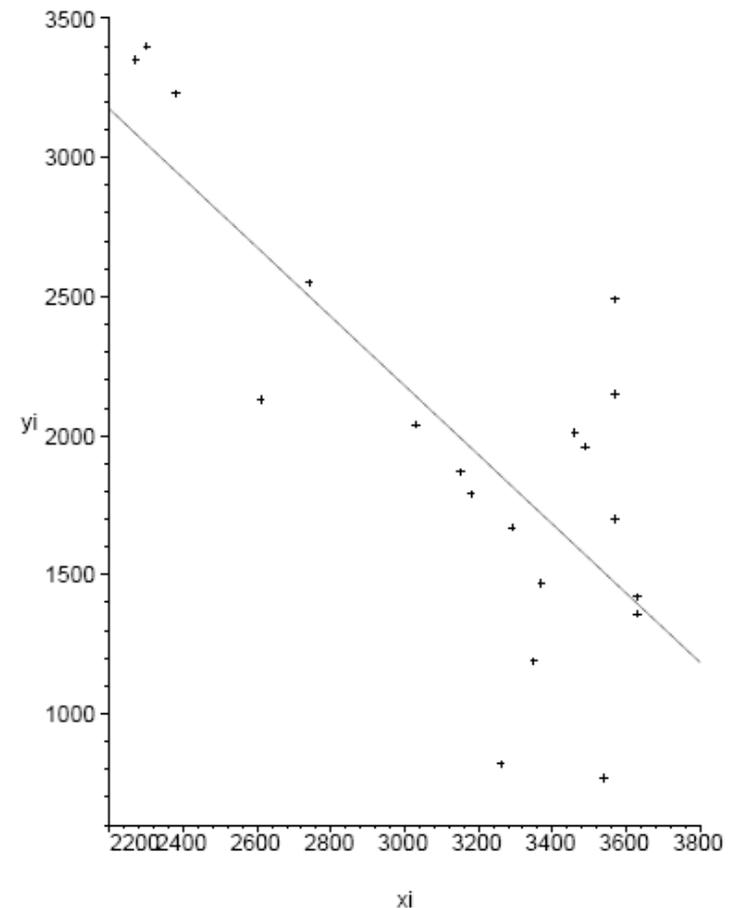
Der lineare Zusammenhang ist also nicht besonders ausgeprägt.



# Beispiel: Lineare Regression

- Für die Merkmale Geburtsgewicht und Gewichtszuwachs erhält man

$$\alpha = 5905 \text{ und } \beta = -1.242$$



# Beispiel: Regressionsanalyse

- 10 LKW-Lieferungen
- Besteht ein Zusammenhang zwischen Weglänge und Lieferzeit?

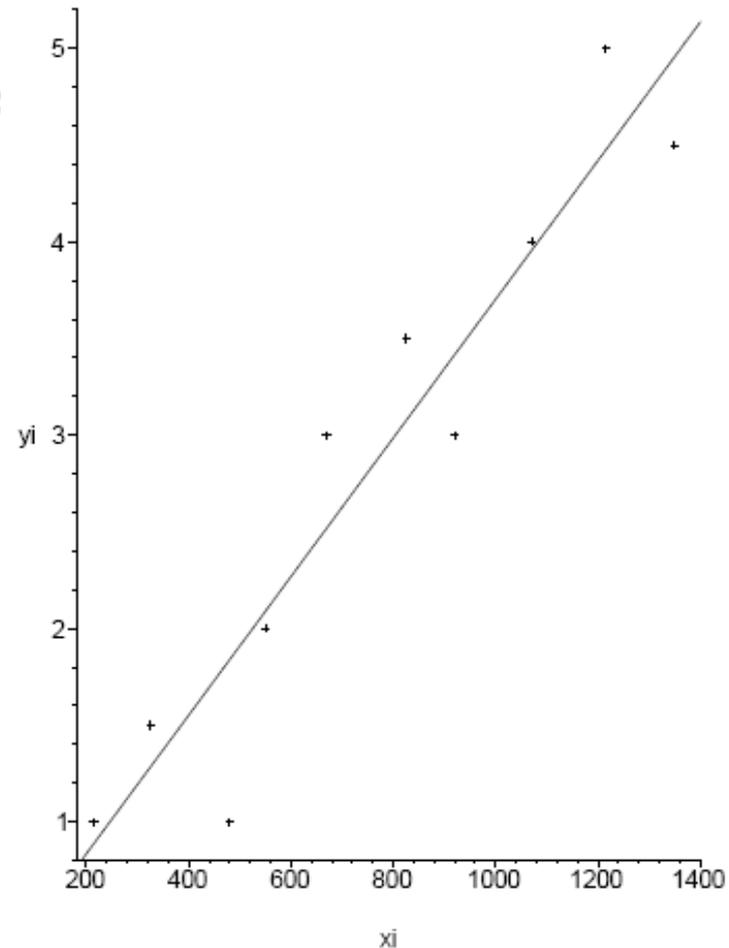
Nummer der Lieferung	1	2	3	4	5	6	7	8	9	10
Weglänge (in km)	825	215	1070	550	480	920	1350	325	670	1215
Lieferzeit (in Tagen)	3.5	1.0	4.0	2.0	1.0	3.0	4.5	1.5	3.0	5.0

# Beispiel: Regressionsanalyse

- Streudiagramm mit Regressionsgerade:

$$\hat{\beta} = \frac{s_{xy}^2}{s_{xx}^2} = 0.0036, \quad \hat{\alpha} = \bar{y}_{10} - \hat{\beta}\bar{x}_{10} = 0.12$$

- $R^2 = 0.90$
- $S^2 = 0.23 = 0.48^2$



# Beispiel: Regressionsanalyse

- Teste  $H_0: \beta = 0$  gegen  $H_1: \beta \neq 0$  zum Niveau  $1-\gamma = 0.05$

$$\bar{x}_{10} = 762, \quad \sum_{i=1}^{10} x_i^2 = 7104300, \quad \sqrt{\sum_{i=1}^{10} x_i^2 - 10 \bar{x}_{10}^2} = 1139.24$$

$$\frac{|\hat{\beta}|}{S / \sqrt{\sum_{i=1}^{10} x_i^2 - 10 \bar{x}_{10}^2}} = \frac{0.0036}{0.48 / 1139.24} = \frac{0.0036}{0.0004} = 9.00$$

$$t_{8,0.975} = 2.306$$

- Lehne  $H_0$  ab. Es besteht also ein signifikanter Zusammenhang.

# Beispiel: Regressionsanalyse

- Konfidenzintervall für  $\beta$  zum Niveau  $\gamma = 0.95$

- Linke Grenze  $\hat{\beta} - t_{n-2, 1-(1-\gamma)/2} S / \sqrt{(n-1)s_{xx}^2}$

- Rechte Grenze  $\hat{\beta} + t_{n-2, 1-(1-\gamma)/2} S / \sqrt{(n-1)s_{xx}^2}$

- Hier:

$$\frac{S}{\sqrt{\sum_{i=1}^{10} x_i^2 - 10 \bar{x}_{10}^2}} = \frac{0.48}{1139.24} = 0.0004$$

$$(0.0036 \mp 2.306 \cdot 0.0004) = (0.0036 \mp 0.0009) = (0.0027, 0.0045)$$

# Beispiel: Regressionsanalyse

- Sei  $x_0 = 1000$ . Dann ist

$$\hat{\alpha} + \hat{\beta}x_0 = 3.70$$

$$S\sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{(n-1)s_{xx}}} = 0.182$$

- Konfidenzintervall für  $\alpha + \beta x_0$  zum Niveau  $\gamma = 0.95$

$$(3.70 \pm 2.306 * 0.182) = (3.28, 4.12)$$

# Beispiel: Regressionsanalyse

- Sei  $x_0 = 0$  (also außerhalb des zur Modellanpassung verwendeten Wertebereichs).
- Dann ist die geschätzte Lieferzeit gegeben durch  $y_0 = 0.12$ .
- Als reine Fahrzeit nicht sinnvoll.
- Mögliche Interpretation: Verladezeit.

# Beispiel: Prognoseintervall

- $x_0 = 1000, \gamma = 0.95$

$$S = 0.48, \tau' = 2.306 * 0.513$$

Prognoseintervall für  $Y_0 = \alpha + \beta + \varepsilon_0$

$$(3.70 \pm 2.306 * 0.513) = (2.52, 4.89)$$

# Beispiel: Konfidenzband

- Konfidenzband für die Regresionsgerade der Lieferzeiten zum Niveau  $\gamma = 0.95$

