

Statistik

TEIL 8

Hans-Hermann Thulke
ba @ thulke-statistics.de
0172-3449934

Statistik

- Daten erheben, verstehen, werten
- Hypothesen prüfen

- Modellieren von Zusammenhängen

Modellieren von Zusammenhängen

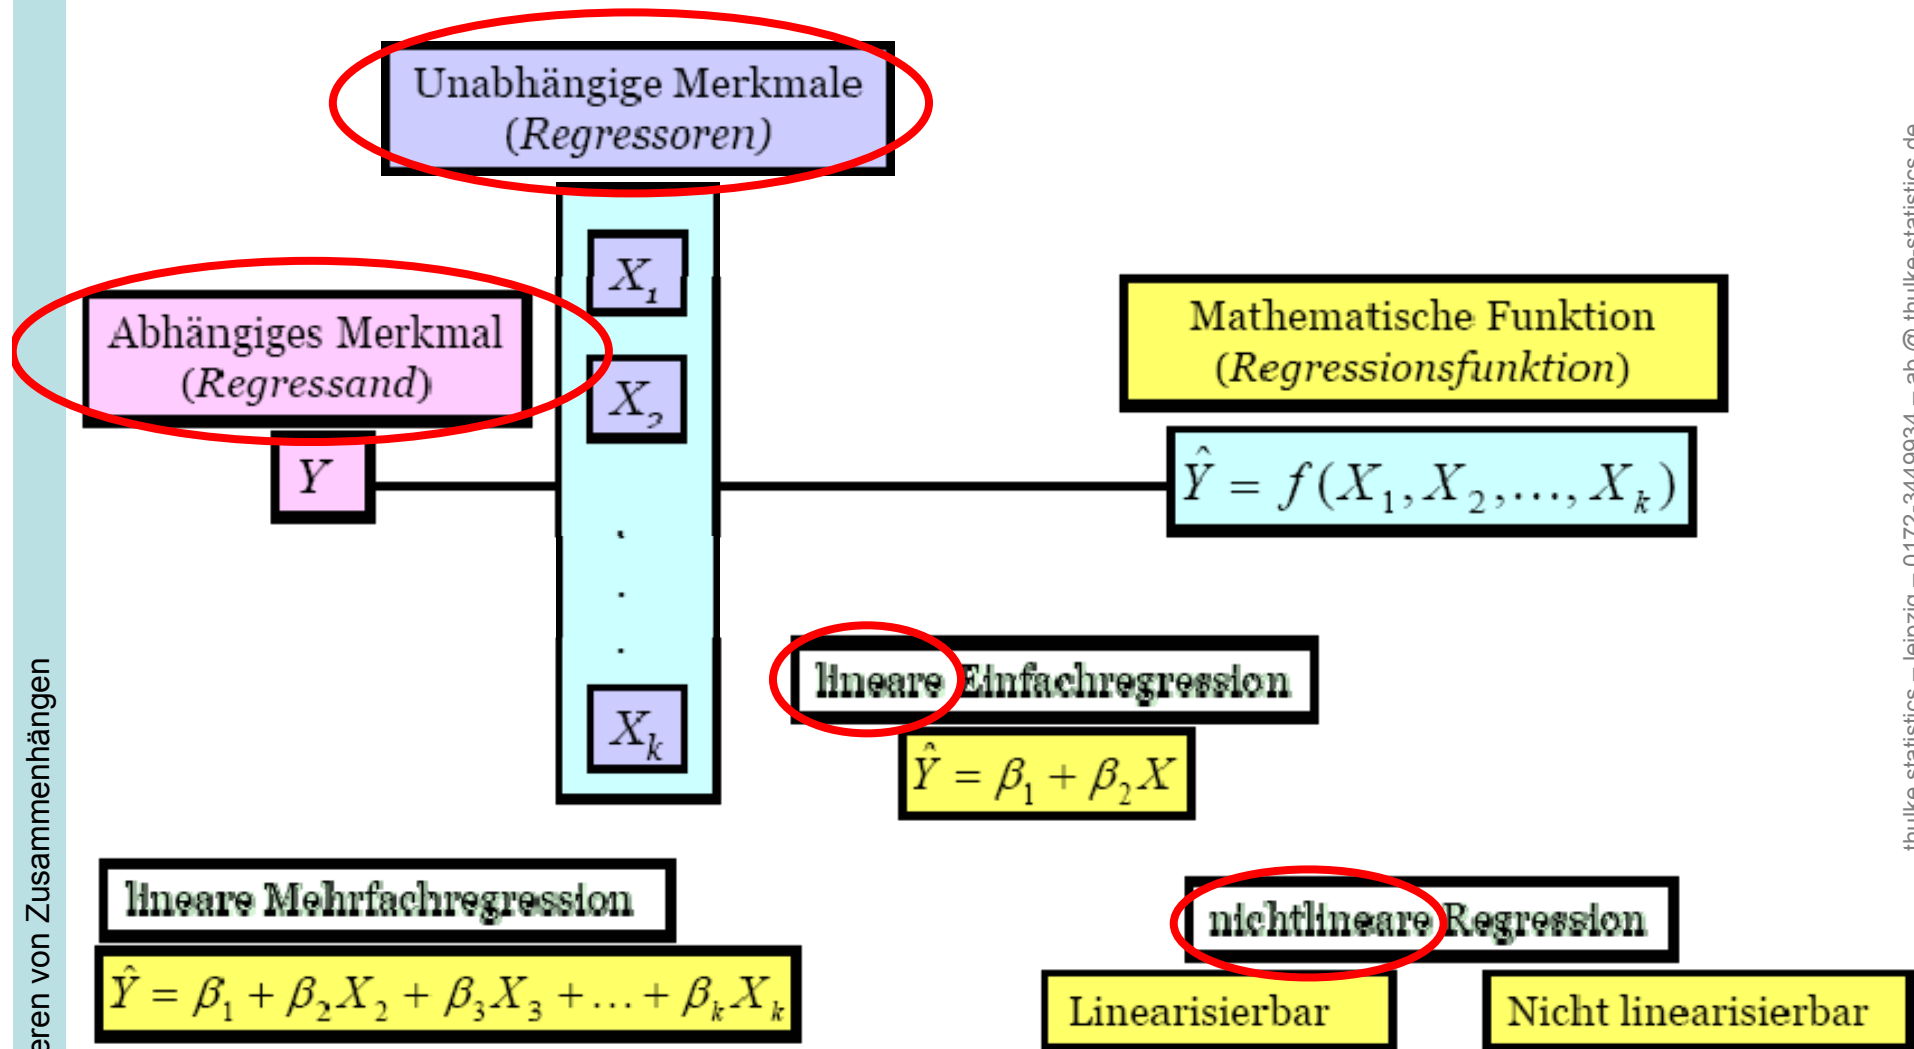
Multivariate Zufallsgrößen

Zusammenhangsmaße

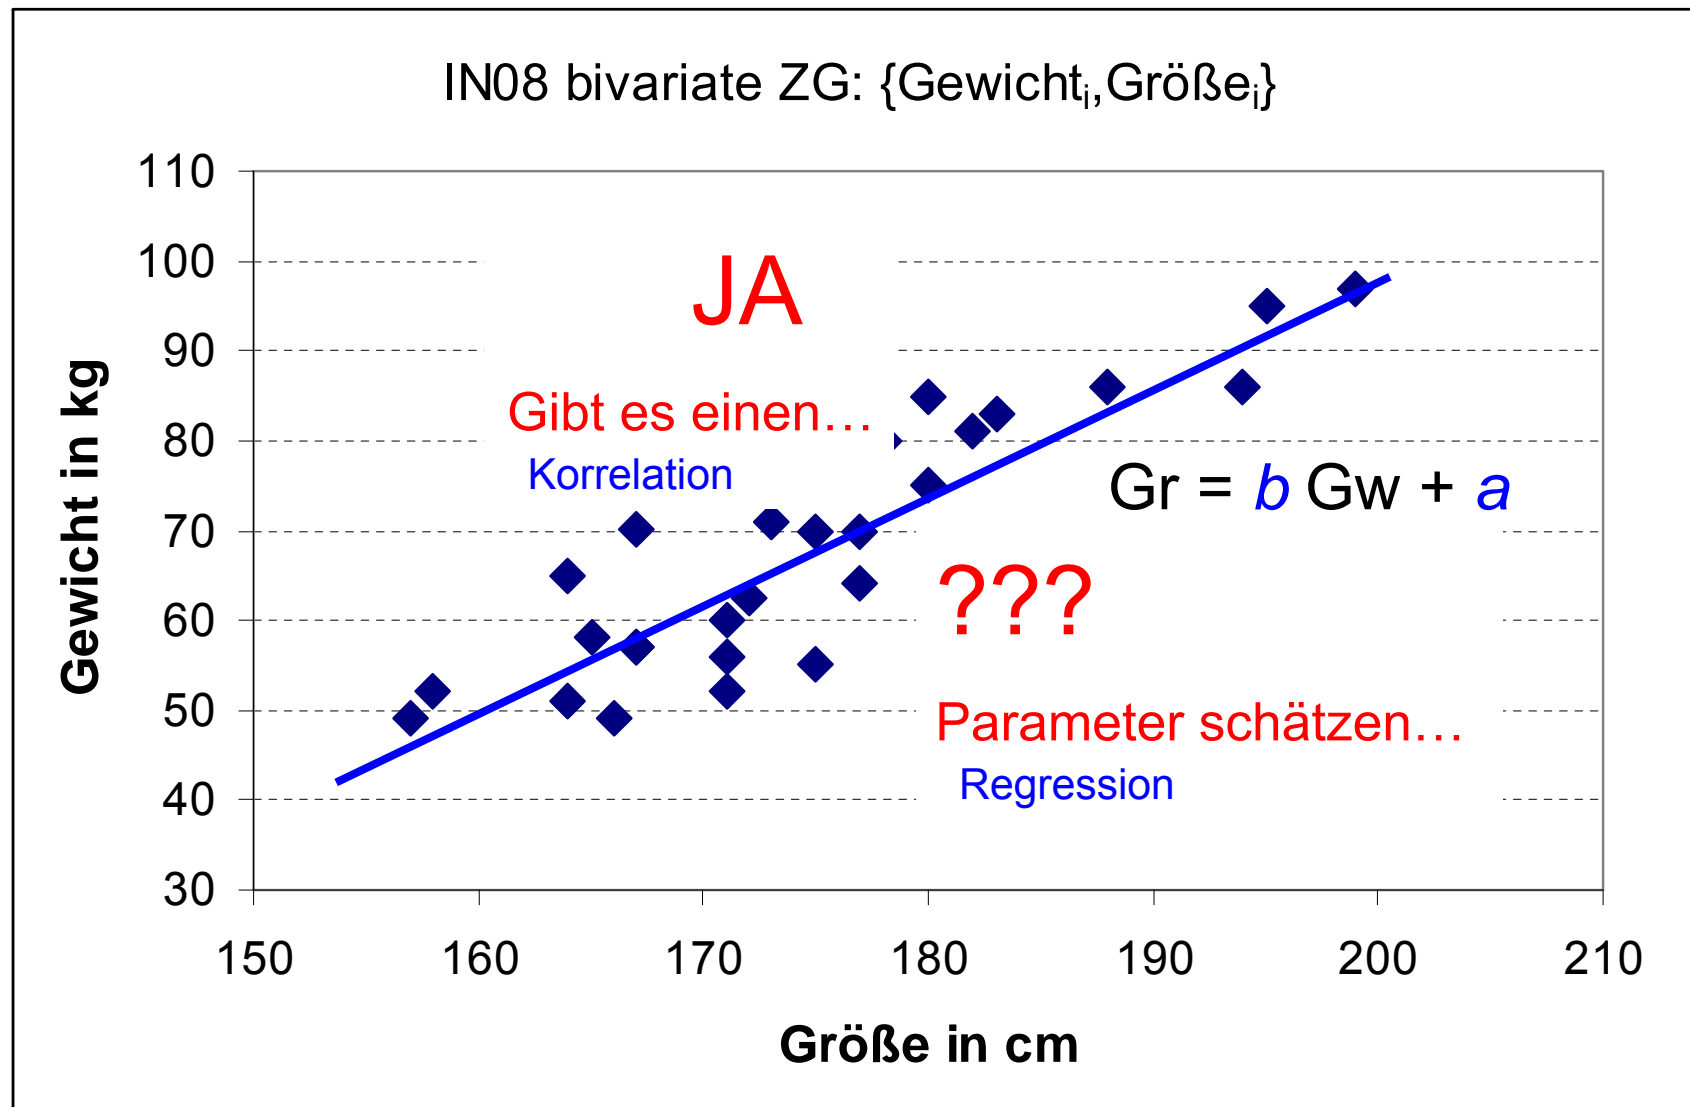
Zusammenhangsmodelle

Trendbestimmung

Zusammenhang - modellieren

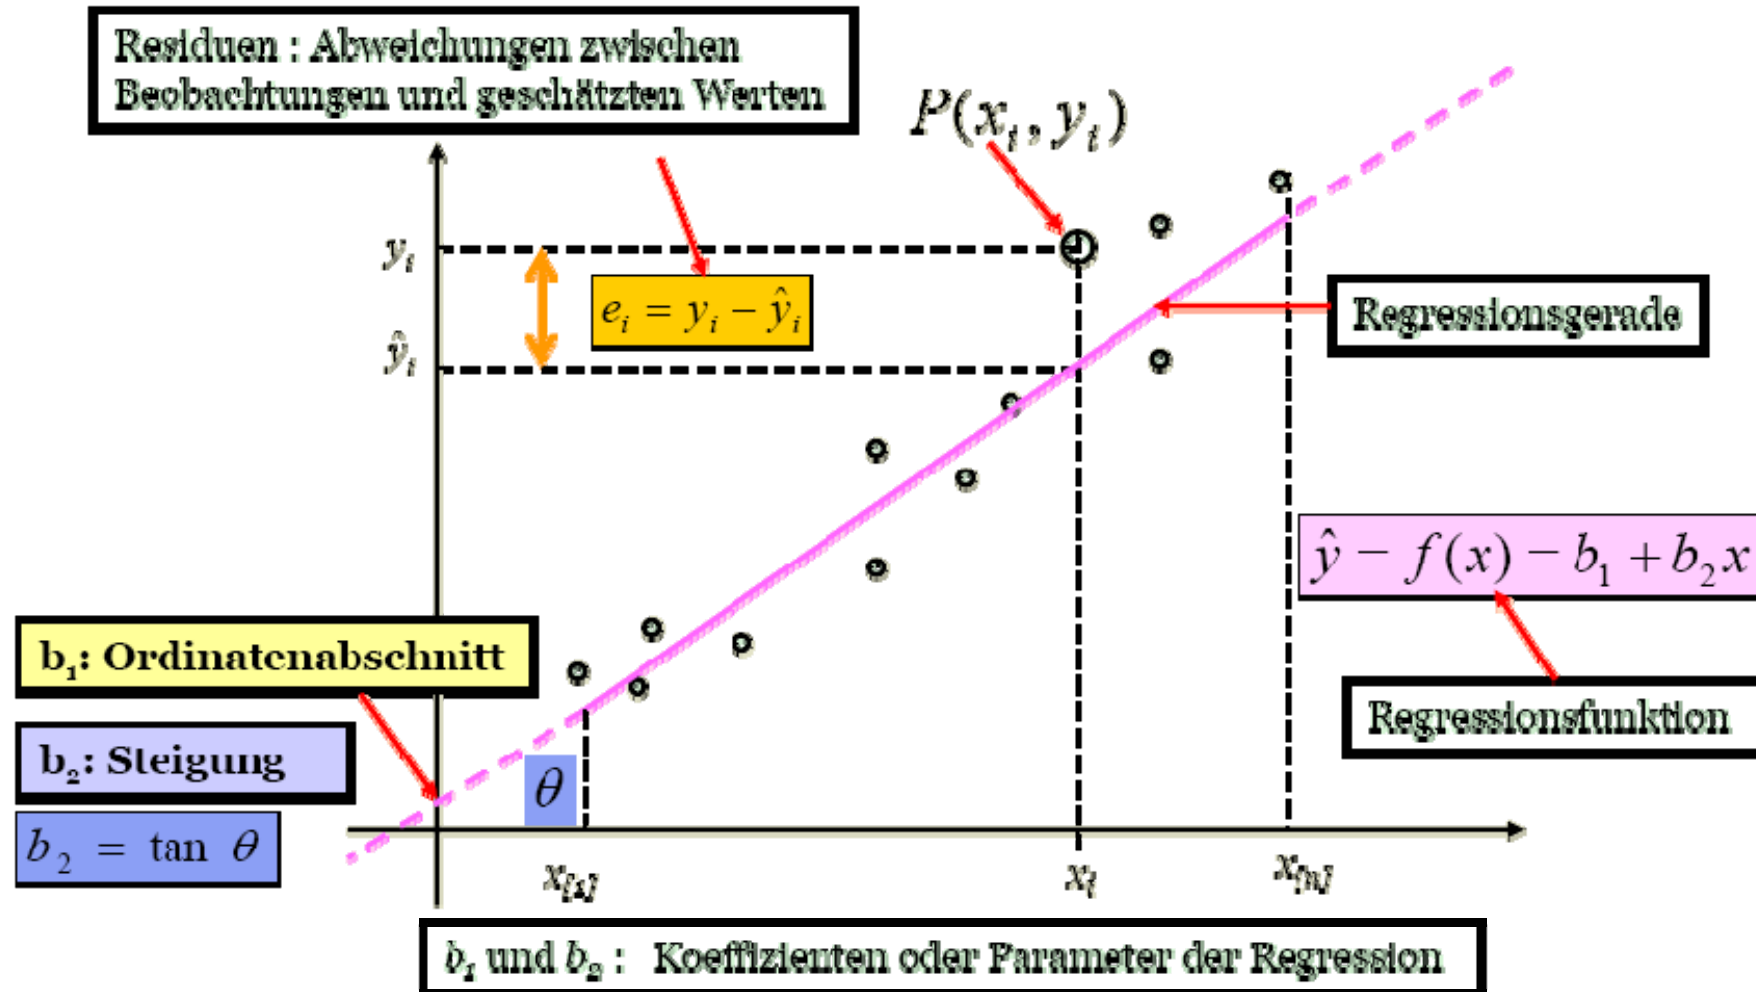


Zusammenhang - modellieren

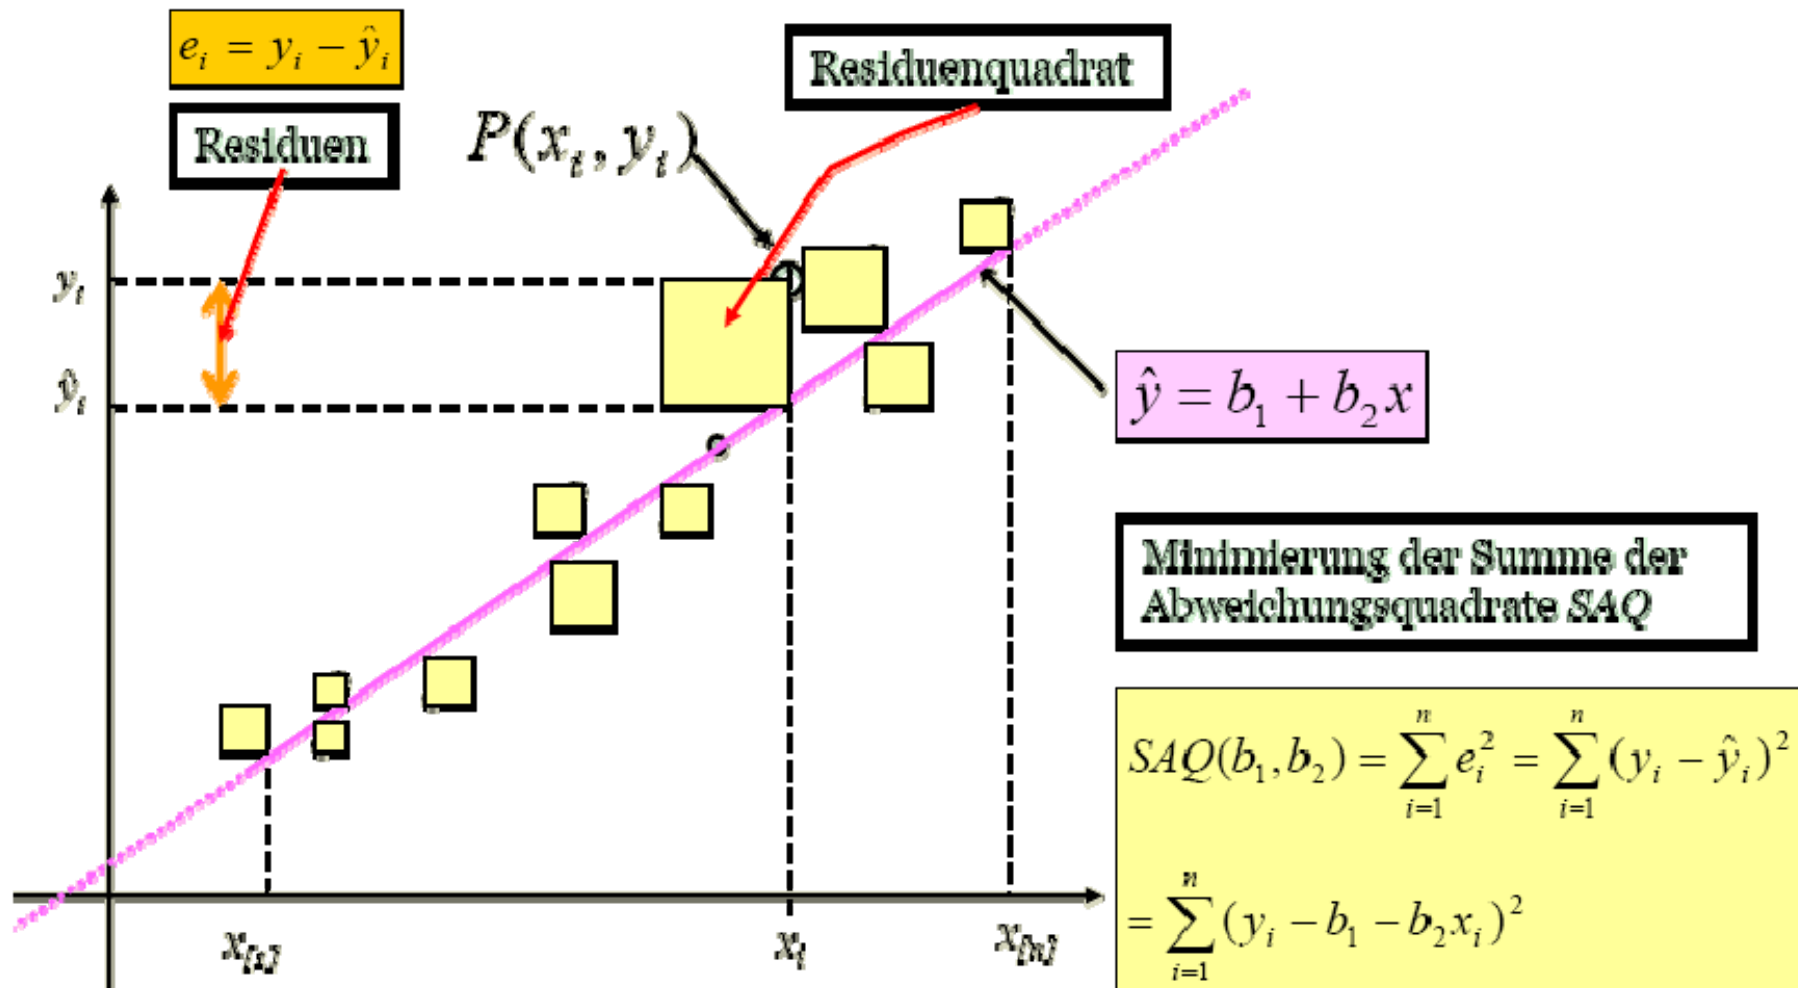


Unser Beispiel... Form? Linear!

Zusammenhang - modellieren



Zusammenhang - modellieren



Zusammenhang - modellieren

Zusammenhang **linear**

$$Y = b_1 + b_2 X$$

Achsen-
abschnitt

Anstieg

$$\text{Gr} = b \text{ Gw} + a$$


$$b_1 = \bar{Y} - b_2 \bar{X}$$

$$b_2 = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2}$$

Formel ergibt sich durch Minimieren der Abweichungsquadrate SAQ (Extremwertberechnung!!!)

Zusammenhang - Beispiel

Besteht ein Zusammenhang zwischen Wuchshöhe und Gewicht?



Berechne

$$\text{Summe } x_i^2 = 826700$$

$$\text{Summe } y_i^2 = 130342$$

$$\text{Summe } x_i \cdot y_i = 324387$$

| Weight | Height |
|--------|--------|
| 64 | 177 |
| 70 | 177 |
| 80 | 178 |
| 75 | 180 |
| 85 | 180 |
| 81 | 182 |
| 83 | 183 |
| 86 | 188 |
| 86 | 194 |
| 95 | 195 |
| 97 | 199 |
| 49 | 157 |
| 52 | 158 |
| 51 | 164 |
| 65 | 164 |
| 58 | 165 |
| 49 | 166 |
| 57 | 167 |
| 57 | 167 |
| 70,1 | 167 |
| 52 | 171 |
| 56 | 171 |
| 60 | 171 |
| 62,5 | 172 |
| 71 | 173 |
| 55 | 175 |
| 70 | 175 |

Es fehlt noch

$$\text{Summe } x_i = 4716$$

$$\text{Summe } y_i = 1836,6$$

Es fehlt noch

$$\text{Summe } x_i = 4716$$

$$\text{Summe } y_i = 1836,6$$


$$\text{Formel oben} = 97035,3$$

$$\text{Unten} = 80244$$

$$b_2 = 1,21$$

$$b_1 = -142,2$$

Zusammenhang - modellieren



$$y_i - \bar{y}$$

Zu erklärende
Abweichung

$$\hat{y}_i - \bar{y}$$

Durch das Modell
erklärte Abweichung

$$e_i = y_i - \hat{y}_i$$

Residuen
oder
nicht erklärte
Abweichungen

Erklärt

Bestimmtheitsmaß :

$$B = \frac{SQE}{SQT} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Total

$$= r_{x;y}^2 * \text{Vorzeichen}(b_2)$$

Zusammenhang - modellieren

Koeffizienten der Regressionsgerade sind **geschätzte** statistische Kenngrößen!!!

Daher... (siehe Formelsammlung S.24-25)

Konfidenzintervall:

b1

für α : $\left[\hat{\alpha} - \hat{\sigma}_{\hat{\alpha}} t_{1-\frac{\alpha}{2}}(n-2), \hat{\alpha} + \hat{\sigma}_{\hat{\alpha}} t_{1-\frac{\alpha}{2}}(n-2) \right]$

für β : $\left[\hat{\beta} - \hat{\sigma}_{\hat{\beta}} t_{1-\frac{\alpha}{2}}(n-2), \hat{\beta} + \hat{\sigma}_{\hat{\beta}} t_{1-\frac{\alpha}{2}}(n-2) \right]$

b2

Test mit T folgender verteilter PG:

$$T_{\alpha_0} = \frac{\hat{\alpha} - \alpha_0}{\hat{\sigma}_{\hat{\alpha}}} \quad \text{und} \quad T_{\beta_0} = \frac{\hat{\beta} - \beta_0}{\hat{\sigma}_{\hat{\beta}}}$$

z.B.


H0: $b_2 \geq b$

HA: $b_2 < b$

$$T_{\beta_0} < -t_{1-\alpha}(n-2)$$


Linearisierung

$$\hat{y} = b_1 \cdot x^{b_2}$$



$$\ln \hat{y} = \ln b_1 + b_2 \ln x \iff \hat{y}^* = b_1^* + b_2 x^*$$

$$\hat{y} = b_1 \cdot e^{b_2 x}$$



$$\ln \hat{y} = \ln b_1 + b_2 x \iff \hat{y}^* = b_1^* + b_2 x$$

ABER:



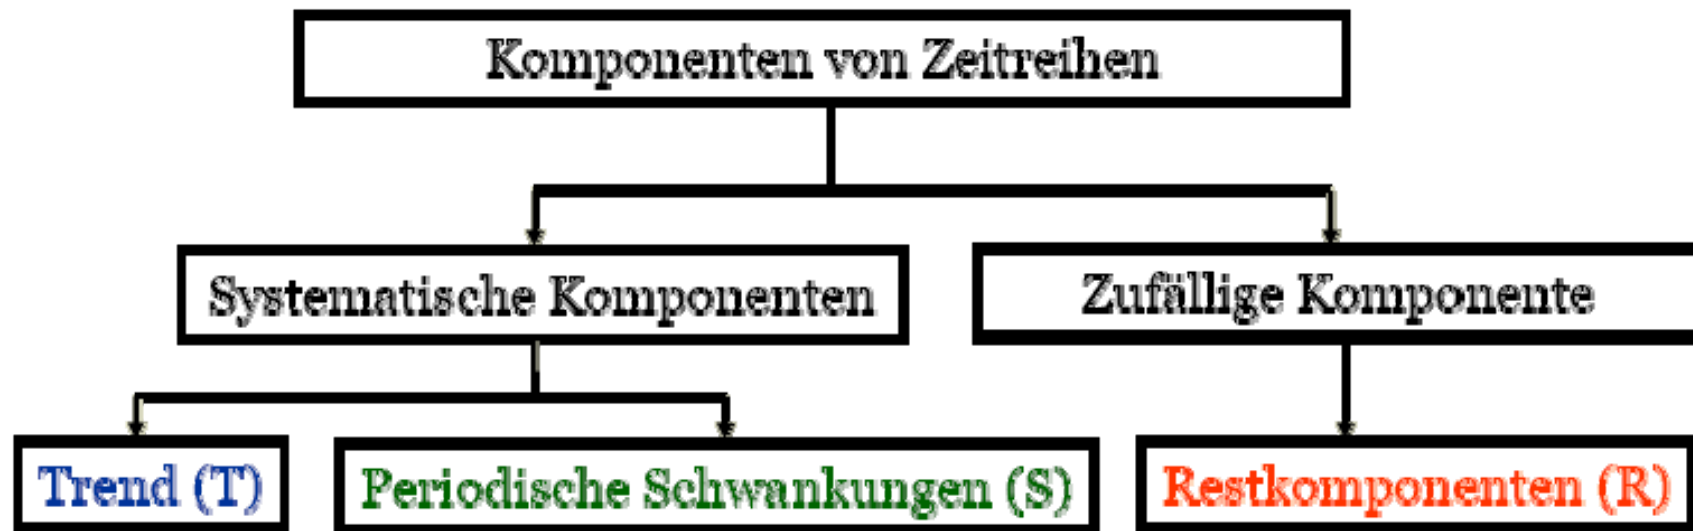
Nicht zu jedem nichtlinearen Zusammenhang gibt es eine Linearisierung

Modellieren von Zusammenhängen

Multivariate Zufallsgrößen
Zusammenhangsmaße
Zusammenhangsmodelle
Trendbestimmung

Zeitreihen

Bei einer Zeitreihe handelt es sich um eine Reihe von Werten (y_1, y_2, \dots, y_n) eines Merkmals (Y), die zu verschiedenen Zeitpunkten oder verschiedenen Zeiträumen ($t=1, 2, \dots, n$) erhoben werden.



Zeitreihen

Bestimmung der **Trendkomponente** einer Zeitreihe

1. Gleitender Durchschnitt der Länge g :

Für **ungerade** g mit
 $g=2k+1$:

$$\tilde{y}_t = \frac{1}{g} \sum_{j=-k}^k y_{t+j}$$

Für **gerade** g mit
 $g=2k$:

$$\tilde{y}_t = \frac{1}{g} \left(\frac{y_{t-k}}{2} + \sum_{j=-k+1}^{k-1} y_{t+j} + \frac{y_{t+k}}{2} \right)$$

Sehr einfach zu rechnen aber verkürzt die Zeitreihe

Zeitreihen

Bestimmung der **Trendkomponente** einer Zeitreihe

2. Schätzen mit Regression:

„t statt x“

$$T_t = b_1 + b_2 \cdot t$$

$$b_1 = \bar{y} - b_2 \cdot \bar{t} \quad b_2 = \frac{n \sum_{t=1}^n (t \cdot y_t) - \sum_{t=1}^n t \cdot \sum_{t=1}^n y_t}{n \sum_{t=1}^n t^2 - \left(\sum_{t=1}^n t \right)^2}$$

Olle Kamellen...

Zeitreihen

Saisonwerte

| $S_{kj} = Y_{kj} - T_{kj}$ | Jahr 1 | Jahr 2 | Jahr 3 | Jahr 4 | Gesamt | S_k |
|----------------------------|--------|--------|--------|--------|---------------|--------------|
| Quartal 1 | -3,46 | -3,68 | -5,22 | -4,66 | -17,02 | -4,25 |
| Quartal 2 | -0,74 | 0,56 | -0,98 | -0,82 | -1,99 | -0,50 |
| Quartal 3 | 1,74 | 2,85 | 1,06 | 1,42 | 7,07 | 1,77 |
| Quartal 4 | 5,33 | 3,59 | 1,85 | 1,16 | 11,93 | 2,98 |

$$S_k = \frac{1}{m} \sum_{j=1}^m s_{kj}$$

für $k=1, \dots, p$ mit $p=4$ und $m=4$

S_k : Durchschnittliche Saisonwert für das Quartal k

p : Anzahl der Quartale

m : Anzahl der Jahre

Modellieren von Zusammenhängen

Multivariate Zufallsgrößen
Zusammenhangsmaße
Zusammenhangsmodelle
Trendbestimmung

Statistik

- Daten erheben, verstehen, werten
- Hypothesen prüfen

- Modellieren von Zusammenhängen