

Mathematik II für Biologen  
Beschreibende Statistik  
Zweidimensionale (bivariate) Daten

Stefan Keppeler

25. April 2014



## Prolog

## Zweidimensionale Stichproben

### Graphisch: Streudiagramm

- Lineare Regression
- Transformationen

### Numerisch: Korrelationen

- Produktmomenten-Korrelation
- Rangkorrelation
- Warnung





## Frühmenschen: Wer denkt, muss weniger kauen

Von Frank Patalong



Fotos ▶

AFP

Spanische Forscher sind auf ein Rätsel in der Entwicklung früher Menschen gestoßen: Je mehr das menschliche Gehirn an Größe gewann, desto kleiner wurden seine Zähne - eine "evolutionäre Paradoxie". Denn eigentlich müsste das Gebiss mitwachsen.

Montag, 07.04.2014 – 08:59 Uhr



<http://www.spiegel.de/wissenschaft/mensch/fruehmenschen-das-gehirn-wuchs-als-die-zaehne-schrumpften-a-962548.html>

“Der Mensch ist der einzige Primat, dessen Backenzähne immer kleiner wurden, während sein Gehirn an Größe zunahm.

“Tatsächlich verschoben sich im Laufe der Entwicklung der Gattung Homo die Proportionen des menschlichen Schädels zwischen Hirnschädel und Gesichtsschädel sowie Kiefer. Während Ersterer immer weiter ‘anschwellt’, um das wachsende Volumen des Gehirns zu beherbergen, geriet der Rest zunehmend ‘zierlicher’.

“[Die Forscher] stellten dabei zum einen fest, dass die Vertreter der Gattung Homo die einzigen Primaten waren und sind, bei denen die geschilderte **Korrelation** in Kontinuität festgestellt werden kann.”



Stichprobe  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  von Paaren von Zahlen.  
Oft:

- ▶  $x$ : Ausgangsgröße, “unabhängige” Variable
- ▶  $y$ : Zielgröße, Idee  $y = f(x)$ , “abhängige” Variable

**Beispiel 1:** Grille (vgl. Mathematik I, Aufgabe 68)

- ▶  $x_i$ : Temperatur [ $^{\circ}\text{C}$ ]
- ▶  $y_i$ : Zirpfrequenz (Tonhöhe) [ $1/\text{s}$ ]

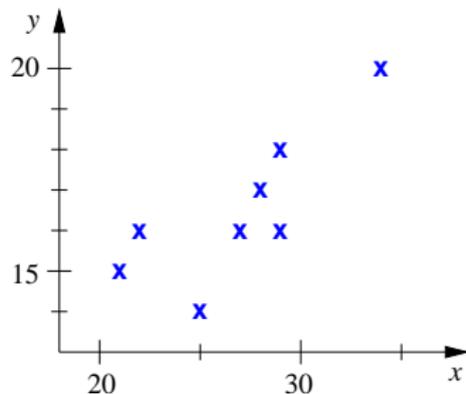
$x_i$	21	22	25	27	28	29	29	34
$y_i$	15	16	14	16	17	16	18	20



$x_i$	21	22	25	27	28	29	29	34
$y_i$	15	16	14	16	17	16	18	20

## Beschreibungsmöglichkeiten

- ▶ Wende Methoden für eindimensionale Stichproben getrennt auf  $x$  und  $y$  an.  
**Nachteil:** Zusammenhang zwischen  $x$  und  $y$  geht verloren.
- ▶ Graphisch: **Streudiagramm** (scatter plot)



Falls Streudiagramm eine Gerade suggeriert: **Lineare Regression**  
(siehe Mathematik I, Vorlesung 14)

$$y(x) = mx + b + \text{“kleiner Fehler”}$$

Wähle  $m$  und  $b$  so, dass

$$\sum_{i=1}^n (y_i - (mx_i + b))^2$$

minimal. Ergebnis:

$$m = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2}, \quad b = \bar{y} - m\bar{x}$$

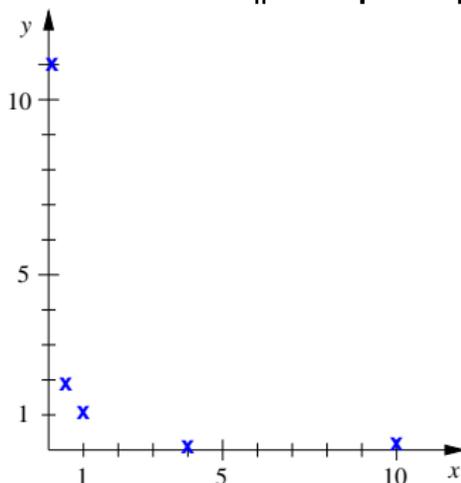


Manchmal erinnert das Streudiagramm erst nach **Transformation(en)** an eine Gerade,

$$x_i \mapsto g(x_i), \quad y_i \mapsto f(y_i).$$

**Beispiel 2:** Andere Stichprobe

$x_i$	0,1	0,5	1,0	4,0	10
$y_i$	11	1,9	1,1	0,15	0,2

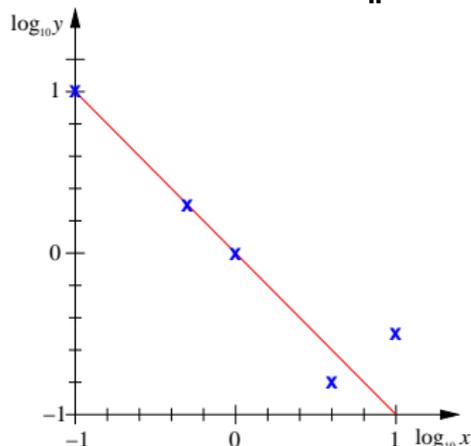


Sieht nicht nach Gerade aus...  
 Vielleicht Potenzgesetz?



$x_i$	0,1	0,5	1,0	4,0	10
$y_i$	11	1,9	1,1	0,15	0,2

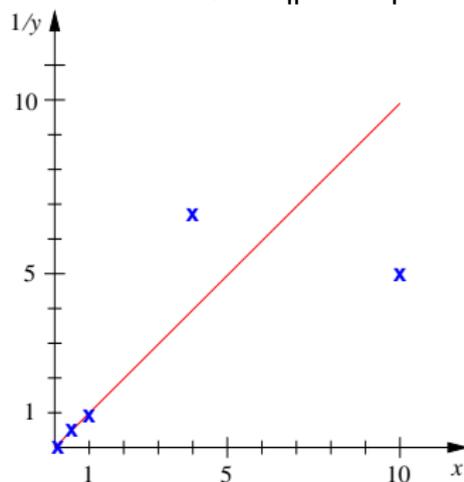
$\log_{10} x_i$	-1,0	-0,3	0,0	0,6	1,0
$\log_{10} y_i$	1,0	0,3	0,0	-0,8	-0,7



Ungefähr Gerade mit Steigung  $-1$ .  
Also wäre auch  $y_i \mapsto 1/y_i$  gut gewesen...

$x_i$	0,1	0,5	1,0	4,0	10
$y_i$	11	1,9	1,1	0,15	0,2

$x_i$	0,1	0,5	1,0	4,0	10
$1/y_i$	0,1	0,5	0,9	6,7	5,0



Gerade mit Steigung 1?



Die **Produktmomenten-Korrelation**  $r_{xy}$  nach **Pearson** misst die Stärke eines **linearen** Zusammenhangs zwischen  $x$  und  $y$ ,

$$r_{xy} := \frac{s_{xy}}{s_x s_y},$$

wobei:

$$s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \quad \text{Stichprobenkovarianz,}$$

$$s_x, s_y \quad \text{Standardabweichungen.}$$

Für den Wert gilt immer:  $-1 \leq r_{xy} \leq 1$ , denn...

**Interpretation:** Kosinus des Winkels zwischen den Vektoren

$$\vec{a} = (x_1 - \bar{x}, \dots, x_n - \bar{x})$$
$$\vec{b} = (y_1 - \bar{y}, \dots, y_n - \bar{y}) \quad , \quad r_{xy} = \frac{\vec{a} \cdot \vec{b}}{|\vec{a}| |\vec{b}|} = \cos \angle(\vec{a}, \vec{b})$$



Für den Wert gilt immer:  $-1 \leq r_{xy} \leq 1$ .

Je näher  $|r_{xy}|$  bei 1, desto stärker ist der lineare Zusammenhang zwischen  $x$  und  $y$ .

$|r_{xy}| = 1$       perfekter linearer Zusammenhang

$r_{xy} \approx 0$       kein linearer Zusammenhang

Vorzeichen (VZ):

VZ von  $r_{xy} =$  VZ der Steigung  $m$  der Regressionsgeraden

### Beispiele:

- ▶ "Grille":  $r_{xy} = 0,8$
- ▶ Beispiel 2:  $r_{xy} = -0,5$
- ▶ weitere qualitativ...



Die **Rangkorrelation** nach **Spearman** misst die Stärke eines **monotonen** Zusammenhangs, zwischen  $x$  und  $y$ ,

$$r_{xy}^{(SP)} = r_{\text{Rang}(x) \text{Rang}(y)}$$

**In Beispiel 2:**

$x_i$	0,1	0,5	1,0	4,0	10
$y_i$	11	1,9	1,1	0,15	0,2

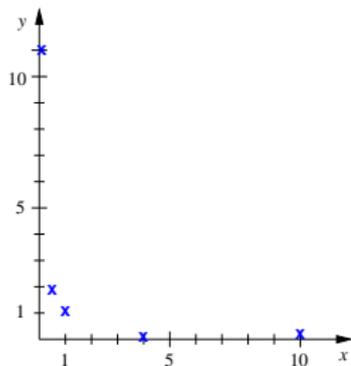
Rang $x_i$	1	2	3	4	5
Rang $y_i$	5	4	3	1	2

$$r_{xy}^{(SP)} = -0,9, \text{ aber } r_{xy} = -0,5:$$

Monotoner Zusammenhang, aber nicht linear.

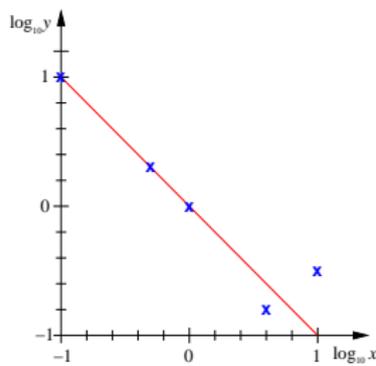
**Übrigens:**  $r_{xy}^{(SP)}$  robust,  $r_{xy}$  nicht. 





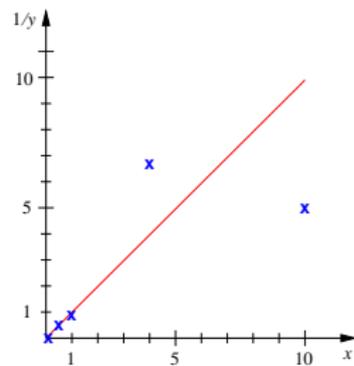
$$r_{xy} = -0,5$$

$$r_{xy}^{(SP)} = -0,9$$



$$r = -0,97$$

$$r^{(SP)} = -0,9$$



$$r = 0,74$$

$$r^{(SP)} = 0,9$$

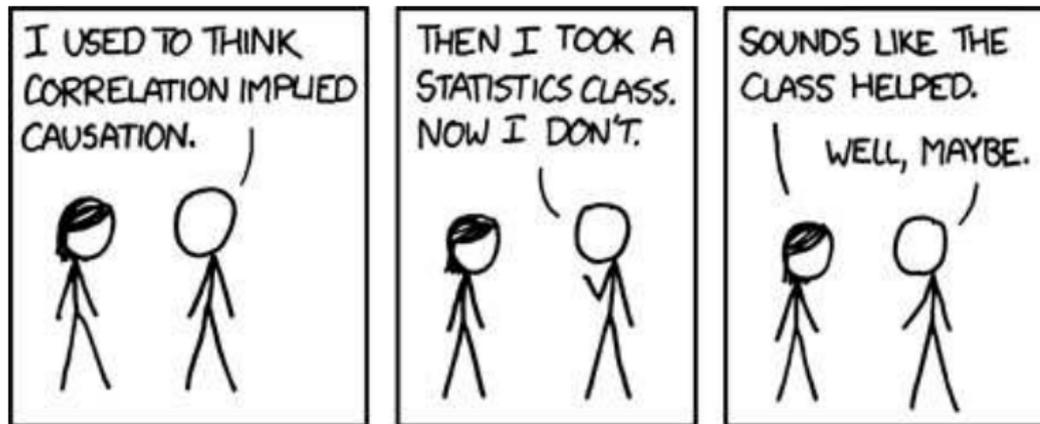
$|r_{xy}^{(SP)}|$  ändert sich nicht bei monotoner Transformation.



## Vorsicht: Interpretation von Korrelationen nicht einfach!

- ▶  $r$  (mit kleinem Betrag) kann rein zufällig von Null verschieden sein. Ob zufällig oder nicht: Schließende Statistik (später)
- ▶ Eine Korrelation  $r \neq 0$  sagt nichts über einen ursächlichen Zusammenhang. Viele Möglichkeiten:
  - ▶  $x$  beeinflusst  $y$ .
  - ▶  $y$  beeinflusst  $x$ .
  - ▶  $x$  und  $y$  haben eine gemeinsame Ursache  $z$ .
  - ▶ Schein-Korrelationen, z.B.: Seien  $x$ ,  $y$ ,  $z$  unkorreliert. Dann sind  $x/z$  und  $y/z$  automatisch korreliert.
  - ▶ V.a. bei Zeitreihen: Unabhängige lineare Trends in  $x$  und  $y$  führen zu “Unsinn-Korrelationen”. Beispiel:
    - $x_i = \# \text{ Störche im Jahr } 1900 + i$
    - $y_i = \# \text{ Geburtenrate im Jahr } 1900 + i$
    - $r_{xy}$  deutlich von Null verschieden  $\Rightarrow$  ???





<http://xkcd.com/552>