

# Die Regressionsgerade

In Reinhard Ramls Dokumenten ist die Notation für die Regressionsgerade

$$\hat{Y} = kX + d,$$

in der Vorlesung zur Psychologischen Methodenlehre und Statistik wird diese Gerade durch

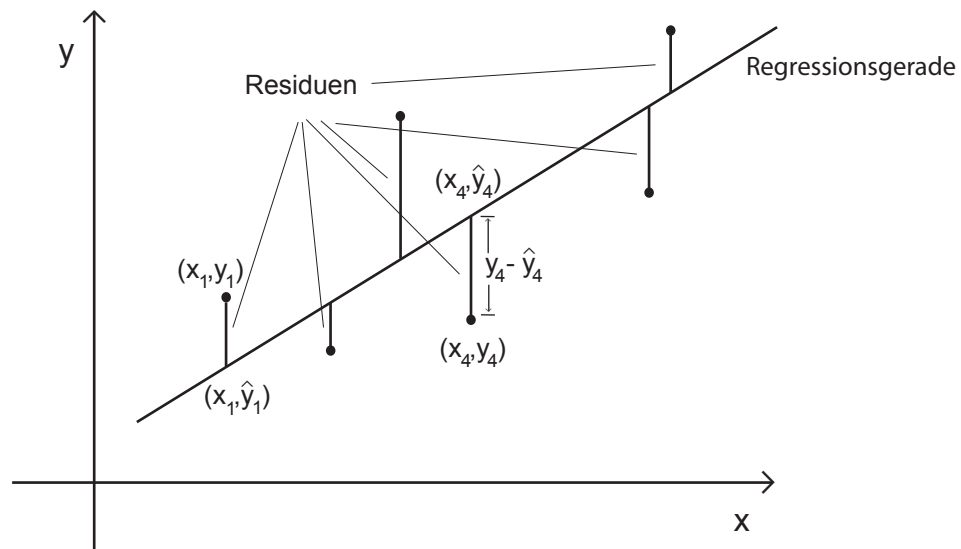
$$\hat{Y} = bX + a$$

bezeichnet.

Wie wir bereits wissen berechnet sich die Regressionsgerade durch die Minimierung der Residuen (**Methode der kleinsten Quadrate**), d.h.

$$Q(a, b) = \sum_i (y_i - \hat{y}_i)^2 = \sum_i (y_i - bx_i - a_i) = \text{minimal.}$$

Dazu eine grafische Veranschaulichung dieser Methode:



Wie kann man die Residuen minimieren? Auf die genaue Vorgangsweise wird in einem Unterkapitel der mathematischen Hintergründe von mathe-online eingegangen: Lokale Minima

Die Idee ist folgende:  $Q(a, b)$  ist eine Funktion der Unbekannten  $a$  und  $b$ . Wir suchen das *Minimum* dieser Funktion. Dazu wird  $Q(a, b)$  abgeleitet (jeweils nach  $a$  und nach  $b$ ) und gleich 0 gesetzt. Wir bekommen also 2 Gleichungen mit 2 Unbekannten, aus denen  $a$  und  $b$  bestimmt werden.

Zur Bestimmung von  $a$  leitet man die Quadratsumme der Residuen nach  $a$  ab, d.h.

$$\frac{\partial Q}{\partial a} = \sum_{i=1}^n \frac{\partial (y_i - bx_i - a)^2}{\partial a} = \sum_{i=1}^n \frac{\partial ((y_i - bx_i)^2 - 2(y_i - bx_i)a + a^2)^2}{\partial a}$$

$$\begin{aligned}
&= \sum_{i=1}^n (0 - 2(y_i - bx_i) + 2a) \\
&= \sum_{i=1}^n -2(y_i - bx_i) + 2a \\
&= 0
\end{aligned}$$

d.h.

$$\begin{aligned}
2 \underbrace{\sum_{i=1}^n a}_{na} &= 2 \underbrace{\sum_{i=1}^n y_i}_{n\bar{y}} - b \underbrace{\sum_{i=1}^n x_i}_{n\bar{x}} \\
na &= n\bar{y} - bn\bar{x}.
\end{aligned}$$

Wir bekommen

$$a = \bar{y} - b\bar{x},$$

wobei  $\bar{x}$  der Mittelwert der  $x_i$  und  $\bar{y}$  der Mittelwert der  $y_i$  ist. Zur Bestimmung von  $b$  leitet man die Quadratsumme der Residuen nach  $b$  ab, d.h.

$$\frac{\partial Q}{\partial b} = \sum_i \frac{\partial (y_i - bx_i - a)^2}{\partial b}$$

Man erhält (diesmal ohne Anführung der Zwischenschritte)

$$b = \frac{\overbrace{\frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x}\bar{y}}{=Cov(X,Y)}}{s_X^2}.$$

$b$  wird auch der *Regressionskoeffizient von  $Y$  auf  $X$*  genannt

Eine nach der Methode der kleinsten-Quadrat Schätzer schneidet stets den Punkt  $(\bar{x}, \bar{y})$ .

$a$  und  $b$  nennt man auch die **Kleinste-Quadrate Schätzer**.

Wenn umgekehrt  $X$  als Funktion von  $Y$  betrachtet wird, dann ist die Regressionsgerade von  $X$  auf  $Y$  berechnet. Man vertauscht einfach  $X$  mit  $Y$  bzw. die  $x_i$  mit den  $y_i$ . Die Kalkulationen erfolgen analog.