

Aufgaben zur Regressionsrechnung

1 Lineare Regression

Von 4 Kfz sind das Alter und die Bremswege bei einer Vollbremsung von 100 km/h zum Stillstand gegeben:

Alter (Jahre)	4	7	11	2
Bremsweg (m)	50	80	70	45

- Bestimmen Sie die Koeffizienten der linearen Regression
- Extrapolieren Sie den erwarteten mittleren Bremsweg für 15 Jahre alte Fahrzeuge
- Zeichnen Sie ein Streudiagramm der Daten und zeichnen Sie die Regression ein.

2 Quasilineare Regression

Von 4 Kfz-Haltern sind im letzten Jahr die Kfz-Haltungskosten pro km und die Kilometerleistung bekannt:

Haltungskosten (€ /km)	0.5	0.2	0.35	0.4
Fahrleistung (km)	14000	42000	14000	25000

- Bestimmen Sie die Koeffizienten der Regression $\hat{y}(x) = a + b/x$
- Bestimmen Sie die mittleren Fixkosten, die variablen Kosten sowie die Preiselastizität bei einer Fahrleistung von 20000 km
- Zeichnen Sie die Daten und die Regressionsfunktion in ein Diagramm ein.

3 Nichtlineare Regression

Der Weltenergieverbrauch in Exajoule (EJ, 10^{18} J) veränderte sich wie folgt:

Jahr	Weltenergieverbrauch (EJ)
1900	15
1920	30
1940	50
1960	130
1972	230

(a) Führen Sie die nichtlineare Regression mit der Funktion

$$\hat{y}(x) = ae^{bx}$$

durch.

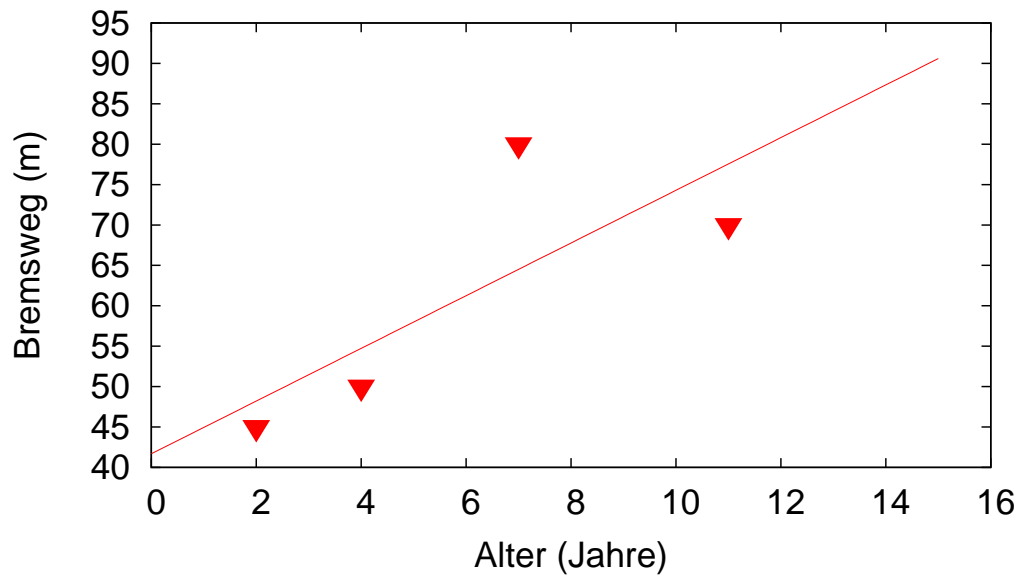
(b) Wie hoch ist der mit diesen Zahlen prognostizierte Verbrauch 1980 und 2020?

Lineare Regression, Lösungen

(a) $\hat{y} = a + bx$, $a = 41.6848$ m, $b = 3.26087$ m/Jahr

(b) Erwarteter Bremsweg: $\hat{y}(15) = a + 15b = 90.6$ m

(c) Scatterplot mit Fitgeraden:

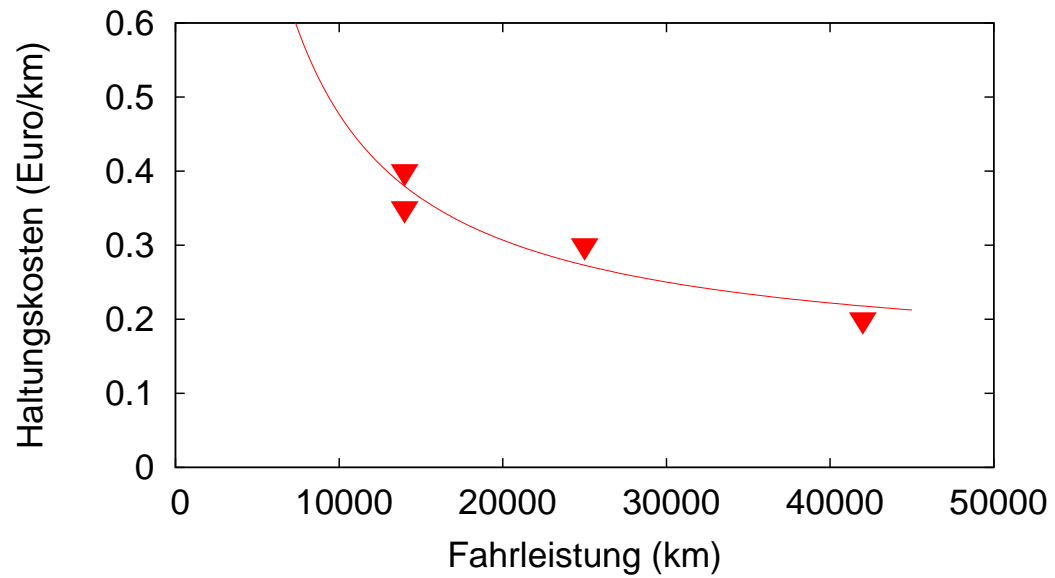


Quasilineare Regression, Lösungen

(a) $\hat{y} = a + b/x$, $a = 0.137 \text{ €}$, $b = 3396 \text{ € km}$

(b) Fixkosten: 3396 € ; Variablen Kosten: 0.137 € /km

(c) Scatterplot mit Fitgeraden:

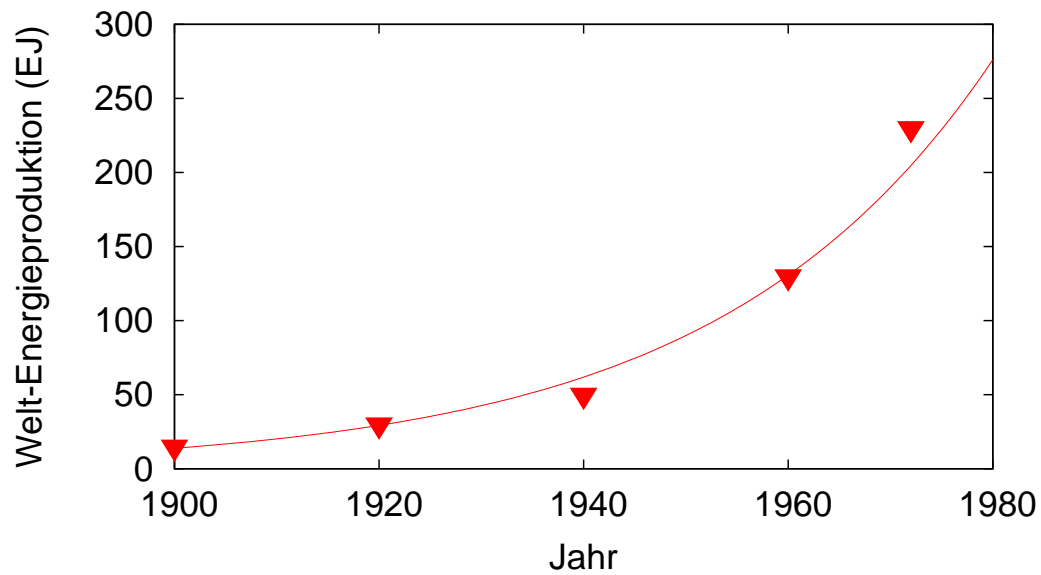



Nichtlineare Regression, Lösungen

(a) $\hat{y}(x) = ae^{b(x-1900)}$, $a = 13.9$ EJ, $b = 0.037/\text{Jahr}$

(b) $\hat{y}(1980) = ae^{80b} = 13.9 * 19.3 = 268$ EJ

(c) Scatterplot mit Fitgeraden:



4 Hintergrundinformation: Regression der Originaldaten vs. Regression transformierter Daten (vgl. Kap. 13.3)

Anhand zweier Regressionsfunktionen zeige ich für allgemeine Daten, dass

- eine *quasilineare* Regression der Originaldaten *äquivalent* zu einer linearen Regression von geeignet transformierten Daten ist,
- eine *auch in den Koeffizienten nichtlineare* Regression der Originaldaten i.A. *nicht* äquivalent zu einer linearen Regression von geeignet transformierten Daten ist.

4.1 Beispiel 1: Quasilineare Regression

Es sollen als Streudiagramm

$$\{(x_i, y_i), i = 1, \dots, n\}$$

gegebene Daten durch die hyperbolische Regressionsfunktion

$$\hat{y}(x) = a + \frac{b}{x}$$

angepasst werden.

4.1.1 Lineare Regression der transformierten Daten

Mit folgender Transformation der unabhängigen Variablen:

$$x = \frac{1}{z}$$

wird die Regressionsfunktion $\hat{y}(z) = a + bz$ linear und man erhält *in der neuen unabhängigen Variable* z die üblichen Ausdrücke für die Koeffizienten:

$$a = \bar{y} - b\bar{z}, \quad b = \frac{s_{zy}}{s_z^2}.$$

Nach Rücktransformation $z = \frac{1}{x}$ erhält man für a und b folgende Ausdrücke:

$$a = \bar{y} - \frac{1}{n} \left(\sum_{i=1}^n \frac{1}{x_i} \right) b, \tag{1}$$

$$b = \frac{\sum_{i=1}^n \frac{y_i}{x_i} - \bar{y} \sum_{i=1}^n \frac{1}{x_i}}{\sum_{i=1}^n \frac{1}{x_i^2} - \frac{1}{n} \left(\sum_{i=1}^n \frac{1}{x_i} \right)^2} \tag{2}$$

4.1.2 Direkte Regression

Da $\hat{y}(x)$ quasilinear ist, ist dies ohne Probleme möglich:

$$F = \sum_{i=1}^n \left(y_i - a - \frac{b}{x_i} \right)^2 \stackrel{!}{=} \min!$$
$$\Rightarrow$$
$$\frac{\partial F}{\partial a} = 2 \sum_{i=1}^n \left(y_i - a - \frac{b}{x_i} \right) (-1) = 0,$$
$$\frac{\partial F}{\partial b} = 2 \sum_{i=1}^n \left(y_i - a - \frac{b}{x_i} \right) \left(\frac{-1}{x_i} \right) = 0.$$

Daraus ein lineares Gleichungssystem für a und b :

$$na + \left(\sum_{i=1}^n \frac{1}{x_i} \right) b = \sum_{i=1}^n y_i,$$
$$\left(\sum_{i=1}^n \frac{1}{x_i} \right) a + \left(\sum_{i=1}^n \frac{1}{x_i^2} \right) b = \sum_{i=1}^n \frac{y_i}{x_i}.$$

Daraus als Ergebnis die Koeffizienten der direkten Regression:

$$a = \bar{y} - \frac{1}{n} \left(\sum_{i=1}^n \frac{1}{x_i} \right) b, \tag{3}$$

$$b = \frac{\sum_{i=1}^n \frac{y_i}{x_i} - \bar{y} \sum_{i=1}^n \frac{1}{x_i}}{\sum_{i=1}^n \frac{1}{x_i^2} - \frac{1}{n} \left(\sum_{i=1}^n \frac{1}{x_i} \right) \left(\sum_{i=1}^n \frac{1}{x_i} \right)} \tag{4}$$

Die Ausdrücke (3) und (1) für den Koeffizienten a sowie (4) und (2) für b sind identisch! Dies ist insofern anschaulich, als

- einerseits bei der Regressionsrechnung ja unsymmetrisch nur die Fehlerquadratsumme F bezüglich der *abhängigen* Variablen y minimiert wird,
- andererseits eine quasilineare Regressionsfunktion durch Transformation ausschließlich der *unabhängigen* Variablen zur linearen Funktion wird. Im quasilinearen Fall wird die Fehlerquadratsumme F also durch die Transformation gar nicht beeinflusst!

4.2 Beispiel 2: In y nichtlineare Regression

Es sollen ein Streudiagramm

$$\{(x_i, y_i), i = 1, \dots, n\}$$

durch die exponentielle Regressionsfunktion

$$\hat{y}(x) = ae^{bx}$$

angepasst werden.

4.2.1 Lineare Regression der transformierten Daten

Mit der Transformation

$$y = e^z$$

wird die Regressionsfunktion $e^{\hat{z}} = ae^{bx}$ nach Logarithmierung linear:

$$\hat{z}(x) = a' + bx,$$

mit der neuen Regressionskonstante $a' = \ln(a)$.

Mit der neuen *abhängigen* Variablen z erhält man die üblichen Ausdrücke für die Koeffizienten:

$$a' = \bar{z} - b\bar{x}, \quad b = \frac{s_{xz}}{s_x^2}.$$

Nach Rücktransformation $z = \ln y$ erhält man für $a = e^{a'}$ und b folgende Ausdrücke:

$$a = e^{a'} = \frac{\exp\left[\frac{1}{n}\sum_{i=1}^n \ln y_i\right]}{\exp(b\bar{x})}, \quad (5)$$

$$b = \frac{\sum_{i=1}^n (x_i - \bar{x}) \left(\ln y_i - \frac{1}{n}\sum_{i=1}^n \ln y_i\right)}{\sum_{i=1}^n \left(\ln y_i - \frac{1}{n}\sum_{i=1}^n \ln y_i\right)^2} \quad (6)$$

4.2.2 Direkte nichtlineare Regression

$$F = \sum_{i=1}^n (y_i - ae^{bx})^2 \stackrel{!}{=} \min!$$

\Rightarrow

$$\frac{\partial F}{\partial a} = 2 \sum_{i=1}^n (y_i - ae^{bx_i}) (-e^{bx_i}) = 0, \quad (7)$$

$$\frac{\partial F}{\partial b} = 2 \sum_{i=1}^n (y_i - ae^{bx_i}) (-ae^{bx_i}) (x_i) = 0. \quad (8)$$

Dieses nichtlineare Gleichungssystem ist nicht analytisch lösbar, aber man kann an Beispielen sehen, dass die Lösungen a und b i.A. nicht äquivalent zu den Gln (5) und (6) sind: Setzen Sie z.B. die sich für das Streudiagramm $\{(-1, e^{-1}), (0, 1), (1, e^4)\}$ aus (5) und (6) sich ergebenden Parameter $a = e^1$, $b = \frac{5}{14}$ in die Bedingung (7) und (8) ein, erhalten Sie Widersprüche.

Fazit: Bei einer nichtlinearen Regressionfunktion, die auch nichtlinear in den Parametern ist, sind die beiden Ansätze i.A. nicht äquivalent; je nach konkreter Situation ist die eine oder die andere Variante "besser"; im Zweifel ist die lineare Regression der transformierten Daten vorzuziehen (vgl. Regression der Langzeit-Dow-Jones-Daten).