



# Allgemeines Lineares Modell

BSc Psychologie SoSe 2023

Prof. Dr. Dirk Ostwald

## (1) Regression

---

Methode der kleinsten Quadrate

Einfache lineare Regression

Selbstkontrollfragen

---

## **Methode der kleinsten Quadrate**

Einfache lineare Regression

Selbstkontrollfragen

## Anwendungsszenario

### Psychotherapie



Mehr Therapiestunden

⇒ Höhere Wirksamkeit?

Unabhängige Variable

- Anzahl Therapiestunden

Abhängige Variable

- Symptomreduktion

# Methode der kleinsten Quadrate


## Beispieldatensatz

$i = 1, \dots, 20$  Patient:innen,  $y_i$  Symptomreduktion bei Patient:in  $i$ ,  $x_i$  Anzahl Therapiestunden von Patient:in  $i$

$y_i$	$x_i$
-3.15	1
2.52	2
-1.18	3
3.06	4
1.70	5
2.91	6
3.92	7
2.31	8
4.63	9
10.91	10
17.56	11
11.52	12
12.31	13
12.12	14
12.13	15
20.37	16
25.26	17
27.75	18
24.93	19
32.49	20

# Methode der kleinsten Quadrate

## Beispieldatensatz



Welcher funktionale Zusammenhang zwischen  $x$  und  $y$  liegt den Daten zugrunde?

## Definition (Ausgleichsgerade)

Für  $\beta := (\beta_0, \beta_1)^T \in \mathbb{R}^2$  heißt die linear-affine Funktion

$$f_\beta : \mathbb{R} \rightarrow \mathbb{R}, x \mapsto f_\beta(x) := \beta_0 + \beta_1 x, \quad (1)$$

für die für einen Datensatz  $\{(x_1, y_1), \dots, (x_n, y_n)\} \subset \mathbb{R}^2$  die Funktion

$$q : \mathbb{R}^2 \rightarrow \mathbb{R}_{\geq 0}, \beta \mapsto q(\beta) := \sum_{i=1}^n (y_i - f_\beta(x_i))^2 = \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2 \quad (2)$$

der quadrierten vertikalen Abweichungen der  $y_i$  von den Funktionswerten  $f_\beta(x_i)$  ihr Minimum annimmt, die *Ausgleichsgerade für den Datensatz*  $\{(x_1, y_1), \dots, (x_n, y_n)\}$ .




### Bemerkungen

- Wir nehmen hier ohne Beweis an, dass das Minimum von  $q$  eindeutig ist.

# Methode der kleinsten Quadrate

Linear-affine Funktionen  $f_{\beta}(x) := \beta_0 + \beta_1 x$




- $\beta_0$ : Schnittpunkt von Gerade und  $y$ -Achse ("Offset Parameter")
- $\beta_1$ :  $y$ -Differenz pro  $x$ -Einheitsdifferenz ("Steigungsparameter")



# Methode der kleinsten Quadrate

Funktion der quadrierten vertikalen Abweichungen

$$q(\beta) := \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2 \quad (3)$$



—  $y_i - (\beta_0 + \beta_1 x_i)$  für  $i = 1, \dots, n$

## Theorem (Ausgleichsgerade)

Für einen Datensatz  $\{(x_1, y_1), \dots, (x_n, y_n)\} \subset \mathbb{R}^2$  hat die Ausgleichsgerade die Form

$$f_{\beta} : \mathbb{R} \rightarrow \mathbb{R}, x \mapsto f_{\beta}(x) := \hat{\beta}_0 + \hat{\beta}_1 x, \quad (4)$$

wobei mit der Stichprobenkovarianz  $c_{xy}$  der  $(x_i, y_i)$ -Werte, der Stichprobenvarianz  $s_x^2$  der  $x_i$ -Werte und den Stichprobenmitteln  $\bar{x}$  und  $\bar{y}$  der  $x_i$ - und  $y_i$ -Werte, respektive, gilt, dass

$$\hat{\beta}_1 = \frac{c_{xy}}{s_x^2} \text{ und } \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad (5)$$

### Bemerkungen

- Mit den Definitionen von  $c_{xy}$  und  $s_x^2$  gilt also

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (6)$$

- Man spricht hier von der Stichprobenkovarianz  $c_{xy}$ , auch wenn die Werte  $x_1, \dots, x_n$  oft nicht als Realisierungen einer Stichprobe  $\xi_1, \dots, \xi_n$  verstanden werden, sondern als gegebene Zahlen.

# Methode der kleinsten Quadrate

## Beweis

Wir betrachten die Summe der quadrierten vertikalen Abweichungen der  $y_i$  von den Funktionswerten  $f(x_i)$  als Funktion von  $\beta_0$  und  $\beta_1$  und bestimmen Werte  $\hat{\beta}_0$  und  $\hat{\beta}_1$ , für die diese Funktion ihr Minimum annimmt, die Summe der quadrierten vertikalen Abweichungen der  $y_i$  von den Funktionswerten  $f(x_i)$  also minimal ist. Wir betrachten also die Funktion

$$q : \mathbb{R}^2 \rightarrow \mathbb{R}, (\beta_0, \beta_1) \mapsto q(\beta_0, \beta_1) := \sum_{i=1}^n \left( y_i - (\beta_0 + \beta_1 x_i) \right)^2. \quad (7)$$

Um das Minimum dieser Funktion zu bestimmen, berechnen wir zunächst die partiellen Ableitungen hinsichtlich  $\beta_0$  und  $\beta_1$  und setzen diese gleich 0. Es ergibt sich zunächst

$$\begin{aligned} \frac{\partial}{\partial \beta_0} q(\beta_0, \beta_1) &= \frac{\partial}{\partial \beta_0} \left( \sum_{i=1}^n \left( y_i - (\beta_0 + \beta_1 x_i) \right)^2 \right) \\ &= \sum_{i=1}^n \frac{\partial}{\partial \beta_0} \left( y_i - (\beta_0 + \beta_1 x_i) \right)^2 \\ &= \sum_{i=1}^n 2 \left( y_i - (\beta_0 + \beta_1 x_i) \right) \frac{\partial}{\partial \beta_0} \left( y_i - \beta_0 - \beta_1 x_i \right) \\ &= -2 \sum_{i=1}^n \left( y_i - \beta_0 - \beta_1 x_i \right) \end{aligned} \quad (8)$$

# Methode der kleinsten Quadrate

Beweis (fortgeführt)

Weiterhin ergibt sich

$$\begin{aligned}\frac{\partial}{\partial \beta_1} q(\beta_0, \beta_1) &= \frac{\partial}{\partial \beta_1} \left( \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2 \right) \\ &= \sum_{i=1}^n \frac{\partial}{\partial \beta_1} (y_i - (\beta_0 + \beta_1 x_i))^2 \\ &= \sum_{i=1}^n 2 (y_i - (\beta_0 + \beta_1 x_i)) \frac{\partial}{\partial \beta_1} (y_i - \beta_0 - \beta_1 x_i) \\ &= -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) x_i\end{aligned}\tag{9}$$

Nullsetzen beider partieller Ableitungen ergibt dann

$$\begin{aligned}\frac{\partial}{\partial \beta_0} q(\beta_0, \beta_1) = 0 \text{ und } \frac{\partial}{\partial \beta_1} q(\beta_0, \beta_1) = 0 \\ \Leftrightarrow -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) = 0 \text{ und } -2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) x_i = 0 \\ \Leftrightarrow \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) = 0 \text{ und } \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) x_i = 0\end{aligned}\tag{10}$$

# Methode der kleinsten Quadrate

Beweis (fortgeführt)

und weiter

$$\sum_{i=1}^n y_i - \sum_{i=1}^n \beta_0 - \beta_1 \sum_{i=1}^n x_i = 0 \text{ und } \sum_{i=1}^n y_i x_i - \sum_{i=1}^n \beta_0 x_i - \beta_1 \sum_{i=1}^n x_i^2 = 0 \quad (11)$$
$$\Leftrightarrow \beta_0 n + \beta_1 \sum_{i=1}^n x_i = \sum_{i=1}^n y_i \text{ und } \beta_0 \sum_{i=1}^n x_i + \beta_1 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n y_i x_i$$

Das sich hier ergebende Gleichungssystem

$$\beta_0 n + \beta_1 \sum_{i=1}^n x_i = \sum_{i=1}^n y_i \quad (12)$$
$$\beta_0 \sum_{i=1}^n x_i + \beta_1 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n y_i x_i$$

wird *System der Normalgleichungen* genannt und beschreibt die notwendige Bedingung für ein Minimum von  $q$ . Auflösen dieses Gleichungssystems nach  $\beta_0$  und  $\beta_1$  liefert dann die Werte  $\hat{\beta}_0$  und  $\hat{\beta}_1$  des Theorems.

# Methode der kleinsten Quadrate

## Beweis (fortgeführt)

Um dies zu sehen, halten wir zunächst fest, dass mit der ersten Gleichung des Systems der Normalgleichungen gilt

$$n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_i = \sum_{i=1}^n y_i \Leftrightarrow \hat{\beta}_0 + \hat{\beta}_1 \bar{x} = \bar{y} \Leftrightarrow \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad (13)$$

Einsetzen der Form von  $\hat{\beta}_0$  in die zweite Gleichung des Systems der Normalgleichungen ergibt dann zunächst

$$\begin{aligned} & \hat{\beta}_0 \sum_{i=1}^n x_i + \hat{\beta}_1 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n y_i x_i \\ \Leftrightarrow & (\bar{y} - \hat{\beta}_1 \bar{x}) \sum_{i=1}^n x_i + \hat{\beta}_1 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n y_i x_i \\ \Leftrightarrow & \bar{y} \sum_{i=1}^n x_i - \hat{\beta}_1 \bar{x} \sum_{i=1}^n x_i + \hat{\beta}_1 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n y_i x_i \quad (14) \\ \Leftrightarrow & -\hat{\beta}_1 \bar{x} \sum_{i=1}^n x_i + \hat{\beta}_1 \sum_{i=1}^n x_i^2 = \sum_{i=1}^n y_i x_i - \bar{y} \sum_{i=1}^n x_i \\ \Leftrightarrow & \hat{\beta}_1 \left( \sum_{i=1}^n x_i^2 - \bar{x} \sum_{i=1}^n x_i \right) = \sum_{i=1}^n y_i x_i - \bar{y} \sum_{i=1}^n x_i \end{aligned}$$

# Methode der kleinsten Quadrate

Beweis (fortgeführt)

Wir halten nun zunächst fest, dass gilt

$$\begin{aligned}\sum_{i=1}^n x_i^2 - \bar{x} \sum_{i=1}^n x_i &= \sum_{i=1}^n x_i^2 - 2\bar{x} \sum_{i=1}^n x_i + \bar{x} \sum_{i=1}^n x_i \\ &= \sum_{i=1}^n x_i^2 - 2\bar{x} \sum_{i=1}^n x_i + n \left( \frac{1}{n} \sum_{i=1}^n x_i \right) \bar{x} \\ &= \sum_{i=1}^n x_i^2 - 2\bar{x} \sum_{i=1}^n x_i + n\bar{x}^2 \\ &= \sum_{i=1}^n \left( x_i^2 - 2\bar{x}x_i + \bar{x}^2 \right) \\ &= \sum_{i=1}^n \left( x_i - \bar{x} \right)^2.\end{aligned}\tag{15}$$

# Methode der kleinsten Quadrate

Beweis (fortgeführt)

Weiterhin halten wir zunächst fest, dass gilt

$$\begin{aligned}\sum_{i=1}^n y_i x_i - \bar{y} \sum_{i=1}^n x_i &= \sum_{i=1}^n y_i x_i - \bar{y} \sum_{i=1}^n x_i - n\bar{y}\bar{x} + n\bar{y}\bar{x} \\ &= \sum_{i=1}^n y_i x_i - \bar{y} \sum_{i=1}^n x_i - \sum_{i=1}^n y_i \bar{x} + \sum_{i=1}^n \bar{y} \bar{x} \\ &= \sum_{i=1}^n y_i x_i - \sum_{i=1}^n y_i \bar{x} - \sum_{i=1}^n \bar{y} x_i + \sum_{i=1}^n \bar{y} \bar{x} \\ &= \sum_{i=1}^n (y_i x_i - y_i \bar{x} - \bar{y} x_i + \bar{y} \bar{x}) \\ &= \sum_{i=1}^n (y_i - \bar{y}) (x_i - \bar{x}).\end{aligned}\tag{16}$$

## Beweis (fortgeführt)

In der Fortsetzung von (14) ergibt sich dann

$$\begin{aligned}\hat{\beta}_1 \left( \sum_{i=1}^n x_i^2 - \bar{x} \sum_{i=1}^n x_i \right) &= \sum_{i=1}^n y_i x_i - \bar{y} \sum_{i=1}^n x_i \\ \Leftrightarrow \hat{\beta}_1 \left( \sum_{i=1}^n (x_i - \bar{x})^2 \right) &= \sum_{i=1}^n (y_i - \bar{y}) (x_i - \bar{x}) \\ \Leftrightarrow \hat{\beta}_1 &= \frac{\sum_{i=1}^n (y_i - \bar{y}) (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \\ \Leftrightarrow \hat{\beta}_1 &= \frac{c_{xy}}{s_x^2}.\end{aligned}\tag{17}$$

□

## Beispieldatensatz Analyse

```
# Einlesen des Beispieldatensatzes
fname      = file.path(getwd(), "1_Daten", "1_Regression.csv")
D          = read.table(fname, sep = ",", header = TRUE)

# Stichprobenstatistiken
x_bar      = mean(D$x_i)           # Stichprobenmittel der x_i-Werte
y_bar      = mean(D$y_i)           # Stichprobenmittel der y_i-Werte
s2x        = var(D$x_i)            # Stichprobenvarianz der x_i-Werte
cxy        = cov(D$x_i, D$y_i)     # Stichprobenkovarianz der (x_i, y_i)-Werte

# Ausgleichsgeradenparameter
beta_1_hat = cxy/s2x              # \hat{\beta}_1, Steigungsparameter
beta_0_hat = y_bar - beta_1_hat*x_bar # \hat{\beta}_0, Offset Parameter

# Ausgabe
cat("beta_0_hat:", beta_0_hat,
    "\nbeta_1_hat:", beta_1_hat)
```

```
> beta_0_hat: -6.19
```

```
> beta_1_hat: 1.66
```

## Beispieldatensatz Visualisierung


```
# Datenwerte
plot(
  D$x_i,
  D$y_i,
  pch      = 16,
  xlab     = "Anzahl Therapiestunden (x)",
  ylab     = "Symptomreduktion (y)",
  xlim     = c(0,21),
  ylim     = c(-10, 40),
  main     = TeX("\\hat{\\beta}_0 = -6.19, \\hat{\\beta}_1 = 1.66$"))

# Ausgleichsgerade
abline(
  coef     = c(beta_0_hat, beta_1_hat),
  lty      = 1,
  col      = "black")

# Legende
legend(
  "topleft",
  c(TeX("$x_i, y_i$"), TeX("$f(x) = \\hat{\\beta}_0 + \\hat{\\beta}_1 x$")),
  lty      = c(0,1),
  pch      = c(16, NA),
  bty      = "n")
```

# Methode der kleinsten Quadrate

## Beispieldatensatz Visualisierung



## Definition (Ausgleichspolynom)

Für  $\beta := (\beta_0, \dots, \beta_k)^T \in \mathbb{R}^{k+1}$  heißt die Polynomfunktion  $k$ ten Grades

$$f_\beta : \mathbb{R} \rightarrow \mathbb{R}, x \mapsto f_\beta(x) := \sum_{i=0}^k \beta_i x^i, \quad (18)$$

für die für einen Datensatz  $\{(x_1, y_1), \dots, (x_n, y_n)\} \subset \mathbb{R}^2$  die Funktion

$$q : \mathbb{R}^{k+1} \rightarrow \mathbb{R}_{\geq 0}, \beta \mapsto q(\beta) := \sum_{i=1}^n (y_i - f_\beta(x_i))^2 = \sum_{i=1}^n \left( y_i - \sum_{i=0}^k \beta_i x^i \right)^2 \quad (19)$$





der quadrierten vertikalen Abweichungen der  $y_i$  von den Funktionswerten  $f_\beta(x_i)$  ihr Minimum annimmt, das *Ausgleichspolynom  $k$ ten Grades* für den Datensatz  $\{(x_1, y_1), \dots, (x_n, y_n)\}$ .

### Bemerkungen

- Wir nehmen hier ohne Beweis an, dass das Minimum von  $q$  eindeutig ist.
- Die Ausgleichsgerade ist das Ausgleichspolynom ersten Grades.
- Die Parameterwerte  $\hat{\beta}_0, \dots, \hat{\beta}_k$  für die  $q$  bei gegebenem Datensatz ihr Minimum annehmen werden an späterer Stelle im Rahmen der Theorie des Allgemeinen Linearen Modells bestimmt werden.

# Methode der kleinsten Quadrate

## Beispieldatensatz Ausgleichspolynome 1ten bis 4ten Grades



$\bullet (x_i, y_i) \quad \text{---} \quad f_{\hat{\beta}}(x) = \sum_{i=0}^k \hat{\beta}_i x^i$

---

Methode der kleinsten Quadrate

**Einfache lineare Regression**

Selbstkontrollfragen

## Motivation

Eine Ausgleichsgerade erlaubt Aussagen über unbeobachtete  $y$ -Werte für gegebene  $x$ -Werte. Der Wert von  $q(\hat{\beta})$  quantifiziert die Güte der Ausgleichsgeradenpassung. Eine Ausgleichsgerade erlaubt allerdings nur implizite Aussagen über die mit der Anpassung verbundene Unsicherheit.

In der einfachen linearen Regression wird die Idee einer Ausgleichsgerade um eine probabilistische Komponente (normalverteilte Fehlervariable) erweitert, um quantitative Aussagen über die mit einer Ausgleichsgeradenanpassung verbundene Unsicherheit machen zu können. Weiterhin erlaubt die einfache lineare Regression, einen Hypothesentest-basierten Zugang zur Einschätzung der angepassten Parameterwerte  $\hat{\beta}_0$  und  $\hat{\beta}_1$ .

Wir betrachten hier zunächst nur das probabilistische Modell der einfachen linearen Regression sowie die auf ihm basierende Maximum Likelihood Schätzung der Parameter  $\beta_0$  und  $\beta_1$ . Die Bewertung von Parameterschätzerunsicherheit sowie parameterzentrierte Hypothesentests behandeln wir an späterer Stelle zunächst im Allgemeinen.

## Definition (Modell der einfachen linearen Regression)

Für  $i = 1, \dots, n$  sei

$$v_i = \beta_0 + \beta_1 x_i + \varepsilon_i \text{ mit } \varepsilon_i \sim N(0, \sigma^2) \quad (20)$$

wobei

- $v_i$  beobachtbare Zufallsvariablen sind, die Werte einer abhängigen Variable modellieren,
- $x_i \in \mathbb{R}$  fest vorgegebene sogenannte *Prädiktorwerte* oder *Regressorwerte* sind, die Werte einer unabhängigen Variable modellieren
- $\beta_0, \beta_1 \in \mathbb{R}$  wahre, aber unbekannte, Offset- und Steigungsparameterwerte sind und
- $\varepsilon_i \sim N(0, \sigma^2)$  unabhängig und identisch normalverteilte nicht-beobachtbare Zufallsvariablen mit wahrem, aber unbekanntem, Varianzparameter  $\sigma^2 > 0$  sind, die Fehler- oder Störvariablen modellieren.

Dann heißt (25) *Modell der einfachen linearen Regression*.

Bemerkung

- Das Modell der einfachen linearen Regression hat drei Parameter,  $\beta_0, \beta_1 \in \mathbb{R}$  und  $\sigma^2 > 0$ .

## Theorem (Datenverteilung der einfachen linearen Regression)

Das Modell der einfachen linearen Regression

$$v_i = \beta_0 + \beta_1 x_i + \varepsilon_i \text{ mit } \varepsilon_i \sim N(0, \sigma^2) \text{ u.i.v. für } i = 1, \dots, n \quad (21)$$

lässt sich äquivalent in der Datenverteilungsform

$$v_i \sim N(\mu_i, \sigma^2) \text{ u.v. für } i = 1, \dots, n \text{ mit } \mu_i := \beta_0 + \beta_1 x_i \text{ und } i = 1, \dots, n \quad (22)$$

schreiben.

Bemerkung

- Die Werte der abhängigen Variable werden im Modell der einfachen linearen Regression also durch unabhängige normalverteilte Zufallsvariablen mit im Allgemeinen unterschiedlichen Erwartungswertparametern modelliert.

# Einfache lineare Regression

## Beweis

Wir zeigen die Äquivalenz für ein  $i$ , die Unabhängigkeit der  $v_i$  zeigen wir an späterer Stelle im Rahmen des Allgemeinen Linearen Modells. Die Äquivalenz beider Modellformen für ein  $i$  folgt direkt aus der Transformation normalverteilter Zufallsvariablen durch linear-affine Funktionen. Speziell gilt im vorliegenden Fall für  $\varepsilon_i \sim N(0, \sigma^2)$ , dass

$$v_i = f(\varepsilon_i) \text{ mit } f : \mathbb{R} \rightarrow \mathbb{R}, \varepsilon_i \mapsto f(\varepsilon_i) := \varepsilon_i + (\beta_0 + \beta_1 x_i) \quad (23)$$


Mit dem WDF Transformationstheorem bei linear-affinen Abbildungen folgt dann

$$\begin{aligned} p_{v_i}(y_i) &= \frac{1}{|1|} p_{\varepsilon_i} \left( \frac{y_i - \beta_0 - \beta_1 x_i}{1} \right) \\ &= N \left( y_i - \beta_0 - \beta_1 x_i; 0, \sigma^2 \right) \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left( -\frac{1}{2\sigma^2} (y_i - \beta_0 - \beta_1 x_i - 0)^2 \right) \\ &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left( -\frac{1}{2\sigma^2} (y_i - (\beta_0 + \beta_1 x_i))^2 \right) \\ &= N \left( y_i; \beta_0 + \beta_1 x_i, \sigma^2 \right). \end{aligned} \quad (24)$$

Definition von  $\mu_i := \beta_0 + \beta_1 x_i$  für  $i = 1, \dots, n$  ergibt dann die Aussage des Theorems.

# Einfache lineare Regression


## Modell der einfachen linearen Regression



•  $x_i$    •  $\beta_0 + \beta_1 x_i$  für  $\beta_0 := 0, \beta_1 := 1$    —  $N(y_i; \beta_0 + \beta_1 x_i, \sigma^2)$  für  $\sigma^2 := 1$ .

# Einfache lineare Regression

## Realisierung des Modells der einfachen linearen Regression



•  $x_i$     •  $\beta_0 + \beta_1 x_i$  für  $\beta_0 := 0, \beta_1 := 1$     —  $N(y_i; \beta_0 + \beta_1 x_i, \sigma^2)$  für  $\sigma^2 := 1$     •  $(x_i, y_i)$

## Theorem (Maximum Likelihood Schätzung)

Es sei

$$v_i = \beta_0 + \beta_1 x_i + \varepsilon_i \text{ mit } \varepsilon_i \sim N(0, \sigma^2) \text{ u.i.v. für } i = 1, \dots, n \quad (25)$$

das Modell der einfachen linearen Regression. Dann sind Maximum Likelihood Schätzer der Modellparameter  $\beta_0, \beta_1$  und  $\sigma^2$  gegeben durch

$$\hat{\beta}_1 := \frac{c_{xy}}{s_x^2}, \quad \hat{\beta}_0 := \bar{y} - \hat{\beta}_1 \bar{x} \quad \text{und} \quad \hat{\sigma}^2 := \frac{1}{n} \sum_{i=1}^n \left( y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i) \right)^2. \quad (26)$$

Bemerkungen

- Wir verzichten hier aus Gründen der Übersichtlichkeit auf die <sup>ML</sup> Superskripte.
- Die ML Schätzer für  $\beta_0$  und  $\beta_1$  sind offenbar mit den Ausgleichsgeradenparametern identisch.

# Einfache lineare Regression

## Beweis

Wir zeigen zunächst, dass die Ausgleichsgeradenparameter  $\hat{\beta}_0$  und  $\hat{\beta}_1$  den entsprechenden ML Schätzern gleichen. Dazu halten wir zunächst fest, dass aufgrund der Unabhängigkeit der  $v_1, \dots, v_n$  die Likelihood-Funktion des Modells der einfachen linearen Regression bezüglich  $\beta_0$  und  $\beta_1$  die Form

$$\begin{aligned} L : \mathbb{R}^2 \rightarrow \mathbb{R}_{>0}, (\beta_0, \beta_1) &\mapsto L(\beta_0, \beta_1) := \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(y_i - (\beta_0 + \beta_1 x_i))^2\right) \\ &= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2\right). \end{aligned} \quad (27)$$

Weil für die Exponentialfunktion gilt, dass für  $a < b \leq 0$  gilt, dass  $\exp(a) < \exp(b)$  wird der Exponentialterm dieser Likelihood-Funktion maximal, wenn der Term

$$q := \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2 \geq 0 \quad (28)$$

minimal und damit  $-q$  maximal wird. Im Rahmen des Beweises der Ausgleichsgeradenform haben wir aber schon gezeigt, dass der Term (28) für

$$\hat{\beta}_1 := \frac{c_{xy}}{s_x^2} \text{ und } \hat{\beta}_0 := \bar{y} - \hat{\beta}_1 \bar{x} \quad (29)$$

minimal wird, und damit  $\hat{\beta}_1$  und  $\hat{\beta}_0$  die Likelihood-Funktion maximieren.

# Einfache lineare Regression

## Beweis (fortgeführt)

In einem zweiten Schritt betrachten wir nun die Likelihood-Funktion des Modells der einfachen linearen Regression bezüglich  $\sigma^2$  an der Stelle von  $\hat{\beta}_0$  und  $\hat{\beta}_1$ . Wir erhalten die Likelihood-Funktion

$$L : \mathbb{R}_{>0} \rightarrow \mathbb{R}_{>0}, \sigma^2 \mapsto L(\sigma^2) = \left(2\pi\sigma^2\right)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i))^2\right) \quad (30)$$

und die entsprechende Log-Likelihood-Funktion

$$\ell : \mathbb{R}_{>0} \rightarrow \mathbb{R}, \sigma^2 \mapsto \ell(\sigma^2) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i))^2 \quad (31)$$

In Analogie zu der Herleitung des ML Schätzers für  $\sigma^2$  im Normalverteilungsmodell (cf. (10) Parameterschätzung) ergibt sich unter Beachtung von

$$\hat{\mu}_n^{\text{ML}} = \hat{\beta}_0 + \hat{\beta}_1 x_i \quad (32)$$

dann hier

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i))^2. \quad (33)$$

## Beispieldatensatz Parameterschätzung

```
# Einlesen des Beispieldatensatzes
fname = file.path(getwd(), "1_Daten", "1_Regression.csv")
D = read.table(fname, sep = ",", header = TRUE)

# Stichprobenstatistiken
n = length(D$y_i) # Anzahl Datenpunkte
x_bar = mean(D$x_i) # Stichprobenmittel der x_i-Werte
y_bar = mean(D$y_i) # Stichprobenmittel der y_i-Werte
s2x = var(D$x_i) # Stichprobenvarianz der x_i-Werte
cxy = cov(D$x_i, D$y_i) # Stichprobenkovarianz der (x_i, y_i)-Werte

# Parameterschätzer
beta_1_hat = cxy/s2x # \hat{\beta}_1, Steigungsparameter
beta_0_hat = y_bar - beta_1_hat*x_bar # \hat{\beta}_0, Offset Parameter
sigsqr_hat = (1/n)*sum((D$y_i-(beta_0_hat+beta_1_hat*D$x_i))^2) # Varianzparameter

# Ausgabe
cat("beta_0_hat:" , beta_0_hat,
    "\nbeta_1_hat:", beta_1_hat,
    "\nsigsqr_hat:", sqrt(sigsqr_hat))

> beta_0_hat: -6.19
> beta_1_hat: 1.66
> sigsq_hat: 3.54
```

## Beispieldatensatz Analyse mit `lm()`

```
# Einlesen des Beispieldatensatzes
```

```
library(car)
```

```
> Lade nötiges Paket: carData
```

```
fname = file.path(getwd(), "1_Daten", "1_Regression.csv")
```

```
D = read.table(fname, sep = ",", header = TRUE)
```

```
# Analyse mit lm()
```

```
model = lm(formula = D$y_i ~ D$x_i, data = D)
```

```
print(model)
```

```
>
```

```
> Call:
```

```
> lm(formula = D$y_i ~ D$x_i, data = D)
```

```
>
```

```
> Coefficients:
```

```
> (Intercept)      D$x_i
```

```
>      -6.19         1.66
```

---

Methode der kleinsten Quadrate

Einfache lineare Regression

**Selbstkontrollfragen**

# Selbstkontrollfragen

---

1. Geben Sie die funktionale Form eine linear-affinen Funktion an.
2. Erläutern Sie die Bedeutung der Parameter einer linear-affinen Funktion.
3. Definieren Sie den Begriff der Ausgleichsgerade.
4. Erläutern Sie die intuitive Bedeutung der Funktion der quadrierten vertikalen Abweichungen.
5. Geben Sie das Theorem zur Ausgleichsgerade wieder.
6. Skizzieren Sie den Beweis des Theorems zur Ausgleichsgeraden.
7. Definieren Sie den Begriff des Ausgleichspolynoms.
8. Erläutern Sie die Motivation des einfachen linearen Regressionsmodells in bezug auf die Ausgleichsgerade.
9. Definieren Sie das Modell der einfachen linearen Regression.
10. Geben Sie das Theorem zur Datenverteilung der einfachen linearen Regression wieder.
11. Skizzieren das Modell der einfachen linearen Regression per Hand.
12. Skizzieren Sie eine Realisierung des Modells der einfachen linearen Regression per Hand.
13. Geben Sie das Theorem zur ML-Schätzung der Parameter der einfachen linearen Regression an.
14. Skizzieren Sie den Beweis des Theorems zur ML-Schätzung der Parameter der einfachen linearen Regression.