

# Eine Einführung in R: Das Lineare Modell

**Bernd Klaus, Verena Zuber**

Institut für Medizinische Informatik, Statistik und Epidemiologie (IMISE),

Universität Leipzig

29. November 2012

## ① Lineare Einfachregression

Einleitung

MLQ - Schätzung

Interpretation und Modelldiagnose

## ② Multiple Regression

Einleitung

Schätzung der Koeffizienten

Einfache Modelldiagnose - Residuenanalyse

## ③ Umsetzung in R

Einfache Regression

Modelldiagnose

Multiple Regression

# Lineare Einfachregression

# Einleitung

- **Ziel der Regressionsanalyse:**  
Welchen Einfluss hat eine Größe  $X$  auf eine andere Zufallsvariable  $Y$ ?
  - $Y$  : metrische Zielvariable, zu erklärende Variable, Regressand
  - $X$  : erklärende Variable, Regressor (zufällig oder deterministisch)
- **Daten:**  
 $n$  Realisierungen  $(y_1, x_1), \dots, (y_n, x_n)$

Ziel der linearen Regression

**Die Lineare Regression untersucht, ob ein linearer Zusammenhang zwischen  $X$  und  $Y$  besteht.**

# Modell der Linearen Regression

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

- $Y$  : Zielvariable, zu erklärende Variable, Regressand
- $X$  : erklärende Variable, Regressor
- $\varepsilon$  : unbeobachtbare Fehlervariable, unabhängig und identisch verteilt (in der Regel als  $N(0, \sigma)$ )
- zu schätzende Koeffizienten des Modells:  $\beta_0, \beta_1$
- $\beta_0$  : Intercept
- $\beta_1$  : Regressionskoeffizient der Variable  $X$

Für  $i = 1, \dots, n$  Beobachtungen:


$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad i = 1, \dots, n$$

# Annahmen: Lineare Regression

- Es besteht ein linearer Zusammenhang zwischen  $X$  und  $Y$
- $Y$  ist metrisch und normalverteilt  
(Kategorial: Logit Regression; Allgemeinere Verteilungen: GLM's)
  - $E(y_i) = \beta_0 + \beta_1 x_i$
  - $Var(y_i) = \sigma^2$
- Homoskedastizität, d.h. die Fehler  $\varepsilon_i$  haben die gleiche Varianz:  
 $Var(\varepsilon_i) = \sigma^2$  für alle  $i = 1, \dots, n$
- Die Fehler  $\varepsilon_i$ , mit  $i = 1, \dots, n$ , sind unabhängig  
(GegenBsp: Zeitreihendaten)
- Die Fehler  $\varepsilon$  sind unabhängig vom Wert der Zielvariable  $Y$

## Beispiel: Simulierte Daten

```
X<-seq(1,6,0.01)
epsilon<-rnorm(length(X), mean=0, sd=1)
Y<-X+epsilon
```



## Schätzung der $\beta_i$

$\beta_0$  und  $\beta_1$  können durch Minimierung der Summe des Quadratischen Fehlers geschätzt werden

Kleinste Quadrate Schätzer:

MLQ

$$\text{MLQ} = \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_i))^2 \rightarrow \min!$$

Dies führt zu folgenden Schätzungen für  $\beta_0$ ,  $\beta_1$  und der gefitteten Wert  $\hat{Y}$  (Regressionsgerade):

Schätzungen

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\text{cov}(X, Y)}{\text{var}(X)}$$

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$$

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X$$

## Testen des $\beta$ -Koeffizienten

Der Regressionskoeffizient  $\beta_1$  der Variable  $X$  ist ein Indikator für den linearen Zusammenhang von  $X$  und  $Y$ . Es gilt:

Zusammenhang zwischen  $\beta_1$  und  $cor(X, Y)$

$$\beta_1 = cor(X, Y) \frac{\sigma_Y}{\sigma_X}$$

Daraus folgt:

- $\beta_1 < 0$ : negativer (linearer) Zusammenhang
- $\beta_1 = 0$ : kein (linearer) Zusammenhang
- $\beta_1 > 0$ : positiver (linearer) Zusammenhang

Es gibt einen einfachen Test, der angibt, ob  $\beta_1$  signifikant ungleich Null ist, d.h. ob ein signifikanter Zusammenhang zwischen  $X$  und  $Y$  besteht.

## Zerlegung der Gesamtstreuung

Die Maßzahl  $R^2$  dient als Hinweis darauf, wie gut ein Regressionsmodell zu den Daten passt. Die Idee hinter diesem Maß ist die sogenannte Streuungszerlegung:

$$SQT = \sum_{i=1}^n (y_i - \bar{y})^2 = \underbrace{\sum_{i=1}^n (y_i - \hat{y}_i)^2}_{SQR} + \underbrace{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}_{SQE}$$

- **SQT**: Sum of Squares Total, die Gesamtstreuung ( $Var(Y)$ )
- **SQE**: Sum of Squares Explained, die durch das Modell erklärte Streuung
- **SQR**: Sum of Squares Residuals, die Rest- oder Residualstreuung

## Bestimmtheitsmaß $R^2$

Liegen die Punkte  $(y_1, x_1), \dots, (y_n, x_n)$  **alle auf einer Geraden**, so ist **SQR** = 0 und die Gesamtstreuung wäre gleich der erklärten Streuung. Das Bestimmtheitsmaß  $R^2$  ist gegeben durch:

### Zerlegung des $R^2$

$$R^2 = \frac{SQE}{SQT} = 1 - \frac{SQR}{SQT} \in [0, 1]$$

Je größer also das  $R^2$  ist, desto besser passt das Modell zu den Daten. Dabei bedeuten:

- $R^2 = 0$ : Die erklärte Streuung ist 0, d.h. das Modell ist extrem schlecht;  $X$  und  $Y$  sind nicht linear abhängig
- $R^2 = 1$ : Die erklärte Streuung entspricht der Gesamtstreuung, das Modell passt perfekt

## Multiple Regression

# Mehrere erklärende Variablen

- **Fragestellung:** Wie ist der Einfluss mehrerer Variablen  $X_1, \dots, X_p$  auf eine Zielgröße  $Y$ ?
- **Realisierungen:**  $(y_1, x_{11}, \dots, x_{1p}), \dots, (y_n, x_{n1}, \dots, x_{np})$
- Modell der **multiplen linearen Regression** mit  $p$  erklärenden Größen  $X = X_1, \dots, X_p$  :

## Modell der multiplen linearen Regression

$$Y = X\beta + \varepsilon$$

$$y_i = \beta_0 + \sum_{j=1}^p \beta_j x_{ij} + \varepsilon_i \quad i = 1, \dots, n, j = 1, \dots, p$$

Dabei ist  $X = (x_{ij})$  die sogenannte Designmatrix.

- **Vorteil zur einfachen Regression:**  
 $\beta_j$  beschreibt den Zusammenhang der  $j$ .ten Variable zu  $Y$  bedingt auf alle übrigen  $j - 1$  Variablen (Kontrolle von ungewollten oder Scheineffekten)

# Least-Squares Schätzer

$\beta_0, \beta_1, \dots, \beta_p$  können (analog zur einfachen linearen Regression) durch Minimierung der Summe des Quadratischen Fehlers geschätzt werden (**Kleinste Quadrate oder Least-Squares**):

$$\text{MLQ} = \sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_{1i} + \dots + \beta_p x_{pi}))^2 \rightarrow \min!$$

Der Least-Squares Schätzer ergibt sich nach Umformen zu:

$$\hat{\beta} = (X^T X)^{-1} X^T Y$$

# Hat-Matrix

Die Matrix

## Hat-Matrix

$$H := X(X^T X)^{-1} X^T$$

bezeichnet man auch als “Hat”-Matrix, da sie die beobachteten Daten  $Y$  in geschätzte Werte

$\hat{Y} = HY = X\hat{\beta}$  verwandelt  
(*puts the hat on Y*).

Es gilt folgender Zusammenhang zu dem Residuenvektor:

$$r = \hat{Y} - Y = HY - Y = (I_n - H)Y$$

$$r \sim N(0, (I_n - H)\sigma)$$

Die Residuen besitzen also die Varianz / Kovarianz

$$\text{Var}(r_i) = \sigma^2(1 - h_{ii}) \quad \text{und} \quad \text{Cov}(\hat{r}_i, \hat{r}_j) = -\sigma^2(1 - h_{ij}), i \neq j$$

# Residuenanalyse

Da die Residuen alle unterschiedliche Varianz besitzen, skaliert man sie auf einheitliche Varianz:

$$r_{i,\text{stud}} = \frac{r_i}{\hat{\sigma} \cdot \sqrt{1 - h_{ii}}} \sim N(0, \sigma)$$

Frage: Sind die Voraussetzungen für das lineare Modell erfüllt?  
Zu untersuchen sind:

**① Anpassung des Modells an die Daten:**

→ Residuen gegen gefittete Wert  $\hat{Y}$

**② Normalverteilung des Fehlers:**

→ QQ-Plot: Quantile der Residuen gegen die theoretische NV

**③ Homoskedastizität des Fehlers:**

→ Standardisierte Residuen gegen gefittete Wert  $\hat{Y}$ ,  
wenn die geeignet mit  $H$  standardisierten Residuen abhängig  
von  $\hat{Y}$  sind, deutet dies auf ungleiche Varianzen der Fehler hin

## Umsetzung in $\mathbb{R}$

## Beispieldaten: “airquality”

- **Ozone**: *Mean ozone in parts per billion from 1300 to 1500 hours at Roosevelt Island*
- **Solar.R**: *Solar radiation in Langleys in the frequency band 4000-7700 Angstroms from 0800 to 1200 hours at Central Park*
- **Wind**: *Average wind speed in miles per hour at 0700 and 1000 hours at LaGuardia Airport*
- **Temp**: *Maximum daily temperature in degrees Fahrenheit at La Guardia Airport*

Mit diesen Daten kann untersucht werden, welchen Einfluss Sonneneinstrahlung, Wind und Temperatur auf die Ozonwerte haben.

## Beispiel in R

Wir laden den Datensatz “airquality”


- `data(“airquality”)`
- Wir untersuchen das Modell:
- $Ozone_i = \beta_0 + \beta_1 \cdot Temp_i + \varepsilon_i$
- ... also die Abhängigkeit des Ozons von der Temperatur
- Aufruf der Funktion `lm()`
- `test <- lm( formula= Ozone ~ Temp, data= airquality)`
- test ist ein Objekt der Klasse `lm`

### Ausgabe in R:

```
Coefficients:  
(Intercept)    Temp  
-146.995      2.429
```

# Scatterplot: Ozone $\sim$ Temp

```
plot(Temp,Ozone)  
abline(test$coefficients, col="red")
```



# Modelldiagnose

- $R^2$  und andere Maße des Modells : `summary(test)`


	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	-146.9955	18.2872	-8.038	9.37e-13
Temp	2.4287	0.2331	10.418	< 2e-16

Multiple R-squared: 0.4877, Adjusted R-squared:  
0.4832

- Koeffizienten: `test$coefficients`
- Gefittete Werte  $\hat{Y}$ : `test$fitted.values`
- Studentisierte Residuen: `ls.diag(test)$std.res`
- Hat-Matrix: `ls.diag(test)$hat`
- Verschiedene Diagnoseplots: `plot(test)`  
oder `plot.lm(test)` (u.a. Residuenanalyse)


# Modelldiagnose in R I: Residuen gegen gefittete Werte

- Residuen gegen gefittete Werte  $\hat{Y}$  zur Untersuchung der Anpassung des Modells an die Daten
- Keine systematische Abweichung, z.B. Trend oder U-Form




## Modelldiagnose in R II: Residuen-QQ

- Plot der studentisierten (besondere Standardisierung) gegen die theoretischen (NV) Residuen zur Untersuchung der Normalverteilung des Fehlers
- Wenn die Residuen normalverteilt sind, sollten sie auf der gestrichelten Geraden liegen



# Modelldiagnose in R III: Standardisierte Residuen gegen $\hat{Y}$

- Standardisierte, absolute Residuen gegen gefittete Werte  $\hat{Y}$  zur Untersuchung der Homoskedastizität des Fehlers
- Keine systematische Abweichung, z.B. ansteigende Varianz



## Multiple Regression in R

- Wir untersuchen nun das Modell:
- $Ozone_i = \beta_0 + \beta_1 \cdot Temp_i + \beta_2 \cdot Solar.R_i + \varepsilon_i$
- ... also die Abhängigkeit des Ozons von der Temperatur und der Sonneneinstrahlung
- Aufruf der Funktion `lm()`
- ```
model2 <- lm( formula= Ozone ~ Temp + Solar.R,  
             data= airquality)
```

### Ausgabe in R:

```
Coefficients:  
(Intercept)    Temp      Solar.R  
-145.70316     2.27847     0.05711
```

Ausgabe von `summary(model2)`:

|             | Estimate   | Std. Error | t value | Pr(> t ) |
|-------------|------------|------------|---------|----------|
| (Intercept) | -145.70316 | 18.44672   | -7.899  | 2.53e-12 |
| Temp        | 2.27847    | 0.24600    | 9.262   | 2.22e-15 |
| Solar.R     | 0.05711    | 0.02572    | 2.221   | 0.0285   |

Multiple R-squared: 0.5103, Adjusted R-squared: 0.5012

Interpretation:

- Solar.R besitzt ein  $\beta$ , das signifikant von Null verschieden ist ( $p$  Wert  $0.0285 < 0.05$ )
- Das  $\beta$  der Variable Temp verändert sich nur leicht durch die Aufnahme von Solar.R: von 2.4287 zu 2.27847
- Das  $R^2$  wird durch die Aufnahme von Solar.R nur noch leicht verbessert: von 0.4832 zu 0.5012
- Durch die beiden Variablen Solar.R und Temp kann die Hälfte der Streuung der Ozonmessungen erklärt werden.

# Spezifikation der Regressionsvariablen

`lm(formula, ...)`

- `formula`: Hier muss das Modell bzw die Variablen des Modelles spezifiziert werden.
- Allgemeiner Aufbau der linearen Einfachregression  
`formula= Y~X`
- Beispiel: `formula= Ozone ~ Temp`
- Allgemeiner Aufbau der multiplen linearen Regression  
`formula= Y~ X1 + X2 + ... + Xp`
- Beispiel: `formula= Ozone ~ Temp + Solar.R`