

Einführung in die induktive Statistik

Friedrich Leisch

Institut für Statistik
Ludwig-Maximilians-Universität München

SS 2009, Lineare Regression



Übersicht

- Wiederholung aus Deskriptive Statistik: Lineare Einfachregression
- Das stochastische Modell der einfachen Regression
- Tests für Parameter
- Korrelation der Parameter
- Multiple Regression

Fragen

- Welche Unsicherheitsfaktoren beeinflussen die Schätzung einer Regressionsgeraden?
- Wenn wir die Körpergröße aus der Unterarmlänge prognostizieren wollen, wie könnten wir vorgehen? Was haben wir bei der Konstruktion von Konfidenzintervallen zu beachten? Wie könnten Konfidenzbereiche aussehen?
- Welche statischen Tests könnten bei der linearen Regression von Interesse sein?

Lineare Einfachregression

Lineare Einfachregression

Modell:

$$y_i = \alpha + \beta x_i + \epsilon_i, \quad i = 1, \dots, n$$

Kleinste-Quadrate-Schätzer:

$$\text{SQR} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - (\hat{\alpha} + \hat{\beta}x_i))^2 \rightarrow \min$$

$$\hat{\alpha} = \bar{y} - \hat{\beta}\bar{x}, \quad \hat{\beta} = \frac{s_{XY}}{s_X^2}$$

Streuungszerlegung

Frage: Wie gut paßt die Regressionsgerade zu den Daten?

Maß für die Variabilität der abhängigen Variablen Y ist die Varianz:

$$\tilde{s}_Y^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2$$

Bei Regression betrachtet man üblicherweise die Quadratsumme

$$\text{SQT} = n\tilde{s}_Y^2 = \sum_{i=1}^n (y_i - \bar{y})^2$$

(SQT = „Sum of sQuares Total“)

Residuen

$$\hat{\epsilon}_i = y_i - \hat{y}_i = y_i - (\hat{\alpha} + \hat{\beta}x_i)$$

Es gilt:

$$\begin{aligned} \sum_{i=1}^n \hat{\epsilon}_i &= \sum_{i=1}^n (y_i - (\hat{\alpha} + \hat{\beta}x_i)) \\ &= \sum_{i=1}^n (y_i - (\bar{y} - \hat{\beta}\bar{x} + \hat{\beta}x_i)) \\ &= \sum_{i=1}^n (y_i - \bar{y} + \hat{\beta}\bar{x} - \hat{\beta}x_i) \\ &= \sum_{i=1}^n (y_i - \bar{y}) + \hat{\beta} \sum_{i=1}^n (\bar{x} - x_i) \\ &= 0 + \hat{\beta}0 = 0 \end{aligned}$$

Streuungszerlegung

$$\text{SQT} = \text{SQE} + \text{SQR}$$

mit

- **Sum of sQuares Total**

$$\text{SQT} = \sum_{i=1}^n (y_i - \bar{y})^2$$

- **Sum of sQuares Explained**

$$\text{SQE} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

- **Sum of sQuares Residual**

$$\text{SQR} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Erklärte Varianz


Bestimmtheitsmaß:

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

$R^2 \approx 0$: Varianz der Residuen identisch zur Varianz von Y , Regressionsgerade horizontal, X hat keinen linearen (!) Einfluß auf Y


$R^2 \approx 1$: Varianz der Residuen fast 0, Daten liegen fast perfekt auf einer Geraden

Erklärte Varianz



Erklärte Varianz: $R^2 \approx 0$

Regressionsgerade horizontal:



Verbesserungsmöglichkeiten

Die deskriptive Anpassung einer Ausgleichgeraden an bivariate Daten kann auf verschiedene Arten verbessert werden: Wünschenswert wäre

- Test, ob die Varianzerklärung signifikant von Null verschieden ist,
- Tests, ob α und β von Null verschieden sind,
- mehr als eine erklärende Variable zu verwenden, und
- kategoriale erklärende Variablen zu verwenden.

Stochastisches Regressionsmodell

Modell bleibt gleich:

$$y_i = \alpha + \beta x_i + \epsilon_i, \quad i = 1, \dots, n$$

Aber wir modellieren nun (zumindest) y_i und ϵ als Zufallsvariablen:

$$Y_i = \alpha + \beta X_i + \epsilon_i$$

Im einfachsten Fall wird X_i als deterministisch angesehen („geplante Experimente“), falls die beobachteten Paare (x_i, y_i) jedoch aus einer Stichprobe stammen, ist auch X_i eine Zufallsvariable.

Eigenschaften von Y

Aus den Modellannahmen folgt direkt:

$$\begin{aligned} \mathbb{E}(Y_i | X_i = x_i) &= \mathbb{E}(\alpha + \beta X_i + \epsilon_i | X_i = x_i) \\ &= \alpha + \beta \mathbb{E}(X_i | X_i = x_i) + \mathbb{E}(\epsilon_i) \\ &= \alpha + \beta x_i \\ \text{Var}(Y_i | X_i = x_i) &= \text{Var}(\alpha + \beta X_i + \epsilon_i | X_i = x_i) \\ &= \beta^2 \text{Var}(X_i | X_i = x_i) + \text{Var}(\epsilon_i) \\ &= \beta^2 0 + \sigma^2 = \sigma^2 \end{aligned}$$

Falls die Fehler normalverteilt sind ($\epsilon_i \sim N(0, \sigma^2)$) gilt weiters:

$$Y_i \sim N(\alpha + \beta X_i, \sigma^2)$$


Annahmen des Modells

$$Y_i = \alpha + \beta X_i + \epsilon_i$$


- Die abhängige Variable Y ist metrisch skaliert.
- Die Regressionsfunktion ist linear.
- Die Fehler ϵ sind unabhängig von X .
- Fehler sind unabhängig identisch verteilt (Homoskedastizität) mit

$$\mathbb{E}\epsilon_i = 0, \quad \text{Var}(\epsilon_i) = \sigma^2$$

Bsp: Herzgewicht von Katzen



Bsp: Herzgewicht von Katzen



Friedrich Leisch, Induktive Statistik 2009

16

Schätzen der Parameter

Da bei der Normalverteilung Kleinstquadrat-Schätzung und Maximum-Likelihood-Schätzung identisch sind, ändern sich die Schätzer nicht:

$$\hat{\alpha} = \bar{y} - \hat{\beta}\bar{x}, \quad \hat{\beta} = \frac{s_{XY}}{s_X^2} = \frac{r_{XY}s_X s_Y}{s_X^2} = r_{XY} \frac{s_Y}{s_X}$$

Als Schätzer für die unbekannte Fehlervarianz σ^2 verwenden wir die Varianz der Residuen:

$$\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{e}_i^2$$

(Nenner $n-2$ wegen 2 davor geschätzten Parametern α und β).

Friedrich Leisch, Induktive Statistik 2009

17

Eigenschaften der KQ-Schätzer

Verteilung der geschätzten Regressionskoeffizienten:

$$\hat{\alpha} \sim N(\alpha, \sigma_{\hat{\alpha}}^2) \quad \text{mit} \quad \text{Var}(\hat{\alpha}) = \sigma_{\hat{\alpha}}^2 = \sigma^2 \frac{\sum_{i=1}^n x_i^2}{n \sum_{i=1}^n (x_i - \bar{x})^2}$$

$$\hat{\beta} \sim N(\beta, \sigma_{\hat{\beta}}^2) \quad \text{mit} \quad \text{Var}(\hat{\beta}) = \sigma_{\hat{\beta}}^2 = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Schätzer $\hat{\sigma}_{\hat{\alpha}}^2$ und $\hat{\sigma}_{\hat{\beta}}^2$ ergeben sich mit $\hat{\sigma}^2$ statt σ^2 .

$\hat{\alpha}$, $\hat{\beta}$ und $\hat{\sigma}$ sind erwartungstreue Schätzer, und konsistent falls $\sum_{i=1}^n (x_i - \bar{x})^2 \rightarrow \infty$ für $n \rightarrow \infty$.

Verteilung der standardisierten Schätzfunktionen:

$$\frac{\hat{\alpha} - \alpha}{\hat{\sigma}_{\hat{\alpha}}} \sim t(n-2) \quad \frac{\hat{\beta} - \beta}{\hat{\sigma}_{\hat{\beta}}} \sim t(n-2)$$

Friedrich Leisch, Induktive Statistik 2009

18

Eigenschaften der KQ-Schätzer

- $(1-\gamma)$ -Konfidenzintervalle für α und β :

$$\begin{aligned} \text{für } \alpha: & \left[\hat{\alpha} - \hat{\sigma}_{\hat{\alpha}} t_{1-\frac{\gamma}{2}}(n-2), \hat{\alpha} + \hat{\sigma}_{\hat{\alpha}} t_{1-\frac{\gamma}{2}}(n-2) \right] \\ \text{für } \beta: & \left[\hat{\beta} - \hat{\sigma}_{\hat{\beta}} t_{1-\frac{\gamma}{2}}(n-2), \hat{\beta} + \hat{\sigma}_{\hat{\beta}} t_{1-\frac{\gamma}{2}}(n-2) \right] \end{aligned}$$

- Testen von Hypothesen: Teststatistiken

$$T_{\alpha_0} = \frac{\hat{\alpha} - \alpha_0}{\hat{\sigma}_{\hat{\alpha}}} \quad \text{und} \quad T_{\beta_0} = \frac{\hat{\beta} - \beta_0}{\hat{\sigma}_{\hat{\beta}}}$$

Friedrich Leisch, Induktive Statistik 2009

19

Prognose

Regressionsgerade:

$$\hat{Y}_0 = \hat{\alpha} + \hat{\beta}x_0$$

Konfidenzintervall für $\hat{Y}_0$:

$$\left[\hat{Y}_0 \pm t_{1-\frac{\gamma}{2}}(n-2)\hat{\sigma}\sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum x_i^2 - n\bar{x}^2}} \right]$$

Beobachtete Werte:

$$Y_0 = \hat{Y}_0 + \epsilon_0 = \hat{\alpha} + \hat{\beta}x_0 + \epsilon_0$$

Konfidenzintervall für Y_0 :

$$\left[\hat{Y}_0 \pm t_{1-\frac{\gamma}{2}}(n-2)\hat{\sigma}\sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum x_i^2 - n\bar{x}^2}} \right]$$

Erklärte Varianz: signifikant?

Die Teststatistik für Korrelation von X und Y ist:

$$T = \frac{r_{XY}}{\sqrt{1 - r_{XY}^2}} \sqrt{n-2} \sim t(n-2)$$

In der Regressionsanalyse ist es üblicher, das Quadrat dieser Statistik zu betrachten:

$$F = T^2 = \frac{r_{XY}^2}{1 - r_{XY}^2} (n-2) = \frac{R^2}{1 - R^2} (n-2) \sim F(1, n-2)$$

Dieser F-Test läßt sich leichter für mehr als eine erklärende Variable verallgemeinern (Varianzanalyse, VO Lineare Modelle).

Ablehnung der Nullhypothese „kein Zusammenhang zwischen X und Y “ zum Signifikanzniveau γ für $F > F_{1-\gamma}(1, n-2)$.

Erklärte Varianz: signifikant?

Zur Beantwortung der Frage, ob des Modell signifikant zur Erklärung der Daten beiträgt, kann man testen, ob

1. $\sigma^2 = \text{Var}(\epsilon)$ kleiner als $\sigma_y^2 = \text{Var}(y)$ ist.
2. R^2 von Null verschieden ist.
3. die Korrelation von X und Y von Null verschieden ist.
4. $\hat{\beta}$ von Null verschieden ist.

Im Fall der linearen Einfachregression sind alle 4 Tests de facto identisch, für mehr als eine erklärende Variable sind

- 1. und 2. identisch
- 3. und 4. verschieden (siehe später)

Erklärte Varianz: signifikant?

Wegen

$$R^2 = \frac{\text{SQE}}{\text{SQT}} = 1 - \frac{\text{SQR}}{\text{SQT}}$$

gilt weiters

$$F = (n-2) \frac{R^2}{1 - R^2} = (n-2) \frac{\text{SQE}/\text{SQT}}{\text{SQR}/\text{SQT}} = \frac{\text{SQE}}{\frac{1}{n-2} \text{SQR}} = \frac{\text{SQE}}{\hat{\sigma}^2}$$

Die F -Statistik wird also groß, wenn

- SQE groß ist (steile Gerade)
- SQR klein ist (kleine Residuen)

Ohne BW: $F = T_{\beta_0}^2$ für $\beta_0 = 0$ in der linearen Einfachregression.

Bsp: Katzen

Welche Koeffizienten sind notwendig?


Für die Hypothesen $\alpha = 0$ und $\beta = 0$ kann man t -Tests formulieren:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-0.3567	0.6923	-0.52	0.6072
Bwt	4.0341	0.2503	16.12	0.0000

$$\hat{\sigma} = 1.452, R^2 = 0.64, F = 259.8, p < 10^{-15}$$


Interpretation: Pro kg Körpergewicht steigt das Herzgewicht im Schnitt um 4.03g, die Konstante ist nicht notwendig.

Bsp: Katzen




Bsp: Unterarm und Körpergröße

```
> arm <- read.csv("arm09.csv")
> summary(arm)
Gruppe Geschlecht Körpergröße Unterarm
a: 8 m:17 Min.:156.0 Min.:21.00
b: 8 w:10 1st Qu.:170.0 1st Qu.:24.50
c:11 Median:176.0 Median:26.00
Mean:176.0 Mean:25.89
3rd Qu.:183.0 3rd Qu.:27.00
Max.:190.0 Max.:29.00
```




Bsp: Unterarm und Körpergröße



Friedrich Leisch, Induktive Statistik 2009

28

Bsp: Unterarm und Körpergröße



Friedrich Leisch, Induktive Statistik 2009

29

Bsp: Unterarm und Körpergröße

```
> lm1 <- lm(Körpergröße ~ Unterarm, data = arm)
> summary(lm1)
Call:
lm(formula = Körpergröße ~ Unterarm, data = arm)

Residuals:
    Min       1Q   Median       3Q      Max
-8.4293 -3.8990 -0.4066  3.1010  9.6010


Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  72.6035    12.8269   5.660 6.83e-06 ***
Unterarm      3.9924     0.4941   8.081 1.96e-08 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 5.006 on 25 degrees of freedom
Multiple R-squared:  0.7231,    Adjusted R-squared:  0.7121
F-statistic: 65.3 on 1 and 25 DF,  p-value: 1.955e-08
```

Friedrich Leisch, Induktive Statistik 2009

30


Bsp: Unterarm und Körpergröße



Friedrich Leisch, Induktive Statistik 2009

31

Bsp: Unterarm und Körpergröße



Friedrich Leisch, Induktive Statistik 2009

32

Bsp: Unterarm und Körpergröße

Parameter haben eine bivariate Normalverteilung mit Varianz-Kovarianzmatrix


```
(Intercept)  Unterarm
(Intercept) 164.52963 -6.3193698
Unterarm    -6.31937  0.2440958
```

und Korrelationskoeffizienten $\rho = -0.9972$.

Friedrich Leisch, Induktive Statistik 2009

33


Bsp: Unterarm und Körpergröße



Friedrich Leisch, Induktive Statistik 2009

34


Bsp: Unterarm und Körpergröße




Friedrich Leisch, Induktive Statistik 2009

35


Bsp: Unterarm und Körpergröße




Bsp: Unterarm und Körpergröße




Bsp: Unterarm und Körpergröße



Bsp: Unterarm und Körpergröße



Bsp: Unterarm und Körpergröße



Friedrich Leisch, Induktive Statistik 2009

40

Bsp: Mietspiegel

Prognose Nettomiete aus Wohnfläche:

```
Call:
lm(formula = nm ~ wfl, data = miete, plot = FALSE)

Residuals:
    Min       1Q   Median       3Q      Max
-225.47 -111.28  -29.36   110.93   374.41


Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)   73.822     77.271   0.955  0.34210
wfl           4.767       1.458   3.270  0.00155 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 140 on 85 degrees of freedom
Multiple R-squared:  0.1118,    Adjusted R-squared:  0.1013 
F-statistic: 10.69 on 1 and 85 DF,  p-value: 0.001553
```

Friedrich Leisch, Induktive Statistik 2009

41


Bsp: Mietspiegel



Friedrich Leisch, Induktive Statistik 2009

42

Bsp: Mietspiegel



Friedrich Leisch, Induktive Statistik 2009

43

Bsp: Mietspiegel

Prognose Logarithmus der Nettomiete aus Wohnfläche:


```
Call:
lm(formula = log(nm) ~ wfl, data = miete, plot = FALSE)

Residuals:
    Min       1Q   Median       3Q      Max
-1.13406 -0.30656  0.01837  0.42550  0.79286


Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  4.901325   0.255908  19.153  < 2e-16 ***
wfl          0.014666   0.004828   3.038  0.00316 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.4635 on 85 degrees of freedom
Multiple R-squared:  0.09794,    Adjusted R-squared:  0.08733 
F-statistic: 9.229 on 1 and 85 DF,  p-value: 0.003164
```

Bsp: Mietspiegel



Bsp: Mietspiegel



Multiple Regression

Multiple lineare Regression

Ziel: Erweiterung der linearen Einfachregression für mehrere Kovariablen

$$X_1, \dots, X_p$$

Daten: $(y_i, x_{i1}, \dots, x_{ip}), i = 1, \dots, n$

Zielvariable Y : metrisch bzw. stetig

Kovariablen: metrisch oder kategorial

Metrische Kovariable x kann auch Transformation $x = f(z)$ einer ursprünglichen erklärenden Variablen z sein, z.B. $x = z^2$, $x = \ln z$, usw..

Bsp: Katzen

„Einfacher“ ist die Einführung von Hilfsvariablen

$m_n = 1$ falls Katze n männlich, sonst 0

$w_n = 1$ falls Katze n weiblich, sonst 0

und die Formulierung des Modells

$$\text{Hwt}_n = \beta_1 m_n + \beta_2 w_n + (\beta_3 m_n + \beta_4 w_n) * \text{Bwt}_n + \epsilon_n$$

das beide Einzel-Regressionsmodelle vereint:

	Estimate	Std. Error	t	p
Constant F	2.9813	1.8428	1.62	0.1080
Constant M	-1.1841	0.9245	-1.28	0.2024
Bwt F	2.6364	0.7759	3.40	0.0009
Bwt M	4.3127	0.3148	13.70	0.0000

Schätzer ident zu Einzelmodellen, Varianz, t und p verschieden.

Bsp: Katzen

Naive Lösung: 2 getrennte Regressionsmodelle

Weiblich:

	Estimate	Std. Error	t	p
Constant	2.9813	1.4855	2.01	0.0508
Bwt	2.6364	0.6254	4.22	0.0001

$$R^2 = 0.28, F = 17.77, p = 0.0001186$$

Männlich:

	Estimate	Std. Error	t	p
Constant	-1.1841	0.9983	-1.19	0.2385
Bwt	4.3127	0.3399	12.69	0.0000

$$R^2 = 0.62, F = 161, p < 10^{-15}$$

Bsp: Katzen

Da $m_n = 1 - w_n$, genügt es, eine der beiden Variablen explizit ins Modell aufzunehmen:

$$\text{Hwt}_n = \beta_1 + \tilde{\beta}_2 m_n + (\beta_3 + \tilde{\beta}_4 m_n) * \text{Bwt}_n + \epsilon_n$$

mit $\tilde{\beta}_2 = \beta_2 - \beta_1$ und $\tilde{\beta}_4 = \beta_4 - \beta_3$.

Unterschiede zwischen den Gruppen kann man testen, indem man auf Unterschiede zwischen den Parametern der Gruppen testet:

	Estimate	Std. Error	t	p
Const F	2.9813	1.8428	1.62	0.1080
Bwt F	2.6364	0.7759	3.40	0.0009
Const M - Const F	-4.1654	2.0618	-2.02	0.0453
Bwt M - Bwt F	1.6763	0.8373	2.00	0.0472

Dummy-Kodierung

Kategoriale erklärende Variable mit k Kategorien $1, \dots, k$ durch $k - 1$ Dummy-Variablen $x^{(1)}, \dots, x^{(k-1)}$ kodiert; mit k als Referenzkategorie.

$$x^{(j)} = \begin{cases} 1, & \text{falls Kategorie } j \text{ vorliegt} \\ 0, & \text{sonst,} \end{cases}$$

wobei $j = 1, \dots, k - 1$.

$x^{(1)} = \dots = x^{(k-1)} = 0 \Leftrightarrow$ Referenzkategorie k liegt vor.

Je nach Software kann auch Kategorie 1 die Referenzkategorie sein (z.B. in R).

Koeffizienten für die Dummy-Variablen geben dann jeweils Differenz zur Referenzkategorie an.

Matrixnotation

$$Y = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix}, X = \begin{pmatrix} 1 & x_{11} & \dots & x_{1p} \\ 1 & x_{21} & \dots & x_{2p} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n1} & \dots & x_{np} \end{pmatrix}, \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix}, \epsilon = \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{pmatrix}$$

Y Beobachtungsvektor der Zielvariablen, X Designmatrix

$Y = X\beta + \epsilon$, $E(\epsilon) = 0$; Annahme: Rang von $X = p + 1$

Standardmodell

Es gilt

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \epsilon_i, \quad i = 1, \dots, n.$$

Dabei sind

$Y_1, \dots, Y_n$ beobachtbare metrische Zufallsvariablen,

$x_{1j}, \dots, x_{nj}$ deterministische Werte der Variablen X_j oder

Realisierungen von Zufallsvariablen X_j ,

$\epsilon_1, \dots, \epsilon_n$ unbeobachtbare Zufallsvariablen, die unabhängig und identisch verteilt sind mit $E(\epsilon_i) = 0$ und $Var(\epsilon_i) = \sigma^2$.

Normalverteilungsannahme:

$$\epsilon_i \sim N(0, \sigma^2) \Leftrightarrow Y_i | x_{i1}, \dots, x_{ip} \sim N(\beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}, \sigma^2)$$

Schätzen & Testen

Schätzer $\hat{\beta} = (\hat{\beta}_0, \dots, \hat{\beta}_p)'$ nach dem KQ-Prinzip

$$\sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_{i1} - \dots - \beta_p x_{ip})^2 = (Y - X\beta)'(Y - X\beta) \rightarrow \min_{\beta}$$

Lösung: KQ-Schätzer

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

Analog zur Einfachregression ist der KQ-Schätzer auch der ML-Schätzer: $Y|X$ ist univariat normalverteilt, BW identisch.

Schätzen & Testen

Gefittete Werte:

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_p x_{ip}$$

Residuen:

$$\hat{\epsilon}_i = Y_i - \hat{Y}_i, \quad i = 1, \dots, n.$$

Schätzer für die Varianz σ^2 :

$$\hat{\sigma}^2 = \frac{1}{n-p-1} \sum_{i=1}^n \hat{\epsilon}_i^2 = \frac{1}{n-p-1} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

Schätzen & Testen

Verteilung der standardisierten Schätzfunktionen:

$$\frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_j} \sim t(n-p-1), \quad j = 0, \dots, p$$

$(1 - \alpha)$ -Konfidenzintervalle für β_j :

$$\left[\hat{\beta}_j - \hat{\sigma}_j t_{1-\frac{\alpha}{2}}(n-p-1), \hat{\beta}_j + \hat{\sigma}_j t_{1-\frac{\alpha}{2}}(n-p-1) \right]$$

Schätzen & Testen

Erwartungstreue:

$$E(\hat{\beta}_j) = \beta_j, \quad j = 0, \dots, p; \quad E(\hat{\sigma}^2) = \sigma^2$$

Varianz der Koeffizienten:

$$\sigma_j^2 := \text{Var}(\hat{\beta}_j) = \sigma^2 v_j; \quad v_j \text{ } j\text{-tes Diagonalelement von } (X'X)^{-1}$$

Geschätzte Varianz der Koeffizienten:

$$\hat{\sigma}_j^2 = \hat{\sigma}^2 v_j$$

(BW Varianz in VO Lineare Modelle)

Schätzen & Testen

Teststatistiken:

$$T_j = \frac{\hat{\beta}_j - \beta_{0j}}{\hat{\sigma}_j}, \quad j = 0, \dots, p$$

Hypothesen und Ablehnbereiche:

Hypothesen		Ablehnbereich
$H_0 : \beta_j = \beta_{0j}$	vs. $H_1 : \beta_j \neq \beta_{0j}$	$ T_j > t_{1-\frac{\alpha}{2}}(n-p-1)$
$H_0 : \beta_j \geq \beta_{0j}$	vs. $H_1 : \beta_j < \beta_{0j}$	$T_j < -t_{1-\alpha}(n-p-1)$
$H_0 : \beta_j \leq \beta_{0j}$	vs. $H_1 : \beta_j > \beta_{0j}$	$T_j > t_{1-\alpha}(n-p-1)$

Schätzen & Testen

Overall-F-Test:

- Hypothesen:

$$H_0: \beta_1 = \dots = \beta_p = 0$$
$$H_1: \beta_j \neq 0 \quad \text{für mindestens ein } j$$

- Teststatistik:

$$F = \frac{R^2}{1 - R^2} \frac{n - p - 1}{p} = \frac{SQE/p}{SQR/(n - p - 1)}$$

- Ablehnungsbereich:

$$F > F_{1-\alpha}(p, n - p - 1)$$

Bsp: Mietspiegel

Prognose Log-Nettomiete aus Fläche, Lage und Badausstattung:


```
Call:
lm(formula = log(nm) ~ wfl + wohngut + badextra, data = miete,
    plot = FALSE)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-1.03636 -0.31017  0.03115  0.30874  0.77012
```


```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  4.983865   0.241857  20.607 < 2e-16 ***
wfl           0.010474   0.004693   2.232 0.028317 *
wohngut       0.364225   0.100320   3.631 0.000488 ***
badextra     -0.237815   0.442659  -0.537 0.592538
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 0.4357 on 83 degrees of freedom
Multiple R-squared:  0.2216,    Adjusted R-squared:  0.1935
F-statistic: 7.877 on 3 and 83 DF,  p-value: 0.0001096
```

Bsp: Mietspiegel



Bsp: Mietspiegel



Bsp: Bundestagswahlen


Beispiel: Wahlen

- Daten von Bundestagswahlen 2002 & 2005: Prozent Zweitstimmen der im Parlament vertretenen Parteien in jedem der 299 Wahlkreise.
- Beobachtung: Obwohl absolute Prozentwerte in jedem Wahlkreis sehr unterschiedlich sind, sind relative Veränderungen (Gewinne, Verluste) meist recht ähnlich.
- Regressionsmodell dient als Basis für Hochrechnungen und Wählerstromanalysen

Friedrich Leisch, Induktive Statistik 2009

65


Ganz Deutschland: Union



Friedrich Leisch, Induktive Statistik 2009

66


Ganz Deutschland: SPD



Friedrich Leisch, Induktive Statistik 2009

67


Bayern: Union



Friedrich Leisch, Induktive Statistik 2009

68


Westen ohne Bayern: Union



Friedrich Leisch, Induktive Statistik 2009

69


Osten: Union



Friedrich Leisch, Induktive Statistik 2009

70


Union 05 vs. SPD 02



Friedrich Leisch, Induktive Statistik 2009

71


Union 05 vs. FDP 02



Friedrich Leisch, Induktive Statistik 2009

72

SPD 05 vs. Grüne 02



Friedrich Leisch, Induktive Statistik 2009

73

Prognose Union in Bayern

```
Call:
lm(formula = UNION05 ~ UNION02 + SPD02 + FDP02 + GRUENE02 + LINKE02 -
1, data = BAYERN)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-0.0206029	-0.0073709	0.0008394	0.0059677	0.0208974

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
UNION02	0.801043	0.010346	77.423	< 2e-16 ***
SPD02	0.006984	0.036099	0.193	0.84758
FDP02	0.869598	0.263899	3.295	0.00207 **
GRUENE02	-0.160878	0.134729	-1.194	0.23948
LINKE02	-0.838218	1.643826	-0.510	0.61291


Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.009956 on 40 degrees of freedom
Multiple R-squared: 0.9996, Adjusted R-squared: 0.9996
F-statistic: 2.247e+04 on 5 and 40 DF, p-value: < 2.2e-16

Friedrich Leisch, Induktive Statistik 2009

74

Prognose Union in Bayern



Friedrich Leisch, Induktive Statistik 2009

75

Prognose Union im Westen oB

Call:
lm(formula = UNION05 ~ UNION02 + SPD02 + FDP02 + GRUENE02 + LINKE02 -
1, data = WOB)

Residuals:

	Min	1Q	Median	3Q	Max
	-0.029766	-0.008920	-0.002461	0.006935	0.046190


Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
UNION02	0.84070	0.01402	59.975	< 2e-16 ***
SPD02	0.05152	0.01153	4.470	1.35e-05 ***
FDP02	0.37827	0.07292	5.188	5.43e-07 ***
GRUENE02	0.04358	0.04466	0.976	0.330382
LINKE02	-1.43033	0.38666	-3.699	0.000283 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.01459 on 190 degrees of freedom
Multiple R-squared: 0.9983, Adjusted R-squared: 0.9983
F-statistic: 2.282e+04 on 5 and 190 DF, p-value: < 2.2e-16

Prognose Union im Westen oB



Prognose Union im Osten

Call:
lm(formula = UNION05 ~ UNION02 + SPD02 + FDP02 + GRUENE02 + LINKE02 -
1, data = OST)

Residuals:

	Min	1Q	Median	3Q	Max
	-0.0299906	-0.0116946	-0.0006884	0.0108240	0.0378346


Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
UNION02	0.9368426	0.0414105	22.623	< 2e-16 ***
SPD02	0.0843117	0.0276189	3.053	0.00352 **
FDP02	-0.5193158	0.2339320	-2.220	0.03064 *
GRUENE02	-0.0007849	0.0557606	-0.014	0.98882
LINKE02	-0.0739955	0.0555572	-1.332	0.18849

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.01536 on 54 degrees of freedom
Multiple R-squared: 0.9968, Adjusted R-squared: 0.9965
F-statistic: 3340 on 5 and 54 DF, p-value: < 2.2e-16

Prognose Union im Osten



Prognose Linke im Osten

```
Call:
lm(formula = LINKE05 ~ UNION02 + SPD02 + FDP02 + GRUENE02 + LINKE02 -
  1, data = OST)
```

Residuals:

Min	1Q	Median	3Q	Max
-0.039197	-0.008196	0.003086	0.010183	0.029752


Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
UNION02	0.006738	0.045149	0.149	0.8819
SPD02	0.243788	0.030112	8.096	6.91e-11 ***
FDP02	0.453942	0.255051	1.780	0.0807 .
GRUENE02	-0.327579	0.060795	-5.388	1.60e-06 ***
LINKE02	0.835727	0.060573	13.797	< 2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.01675 on 54 degrees of freedom
Multiple R-squared: 0.996, Adjusted R-squared: 0.9956
F-statistic: 2687 on 5 and 54 DF, p-value: < 2.2e-16

Prognose Linke im Osten



In der Realität

Klarerweise sind die hier vorgestellten Modelle für „echte“ Hochrechnungen oder Wählerstromanalysen zu einfach. Es sollte auch berücksichtigt werden:

- Wahlberechtigte
- Nichtwähler
- andere Parteien
- Zusammenhänge zwischen den Parteien (Modelle simultan schätzen)
- Wählerströme strikt positiv
- ...

Wegen des extrem hohen R^2 liefern aber auch diese einfachen Modelle schon recht gute erste Erkenntnisse.