



# Multiple Lineare Regression (Teil 2)

Peter von Rohr

# Outline

- Tests und Konfidenzintervalle
- Analyse der Residuen
- Modellwahl

# Annahmen für ein lineares Modell


- Ausser, dass die Matrix  $\mathbf{X}$  vollen Rang hat ( $p < n$ ) wurden bis jetzt keine Annahmen gemacht
- 1 Lineares Modell ist korrekt  $\rightarrow E(\epsilon) = \mathbf{0}$
- 2 Die Werte in  $\mathbf{X}$  sind exakt
- 3 Die Varianz der Fehler ist konstant ("Homoskedazidität") für alle Beobachtungen  $\rightarrow Var(\epsilon) = \mathbf{I} * \sigma^2$
- 4 Die Fehler sind unkorreliert
- 5 Weitere Eigenschaften folgen, falls die Fehler normal verteilt sind

Was passiert, wenn Annahmen nicht erfüllt sind?

# Massnahmen und Alternativen

- Falls Annahme 3 (konstante Varianzen) verletzt ist, verwenden wir weighted least squares
- Falls Annahme 5 der Normalität nicht gilt, verwenden wir robuste Methoden
- Falls Annahme 2 falsch ist, brauchen wir eine Methode namens “errors in variables”
- Falls Annahme 1 nicht zutrifft, brauchen wir ein nicht-lineares Modell

# Annahmen 1 und 4 nicht erfüllt



# Mehrere Regressionen mit einer Variablen

- **Wichtig:** Multiple lineare Regression nicht durch mehrere Regressionen mit einer Variablen ersetzen
- Beispiel:  $y = 2 * x_1 - x_2$

---

<b>x1</b>	0	1	2	3	0	1	2	3
<b>x2</b>	-1	0	1	2	1	2	3	4
<b>y</b>	1	2	3	4	-1	0	1	2

---

## Einfache Regression mit x2

```
x1 <- c(0, 1, 2, 3, 0, 1, 2, 3)
x2 <- c(-1,0,1,2,1,2,3,4)
y <- 2*x1-x2
dfData <- data.frame(x1=x1, x2=x2, y=y)
lm_simple_x2 <- lm(y ~ x2, data = dfData)
```

# Resultat

Table 2: Fitting linear model:  $y \sim x_2$

	Estimate	Std. Error	t value	Pr(> t )
<b>x2</b>	0.1111	0.4057	0.2739	0.7934
<b>(Intercept)</b>	1.333	0.8607	1.549	0.1723

- Original:  $y = 2 * x_1 - x_2$

# Eigenschaften der Least Squares Schätzer

- Modell:  $\mathbf{y} = \mathbf{X}\beta + \epsilon$ , mit  $E[\epsilon] = \mathbf{0}$ ,  $Cov(\epsilon) = \mathbf{I} * \sigma^2$
- 1  $E[\hat{\beta}] = \beta \rightarrow$  unverzerrter Schätzer (unbiasedness)
- 2  $E[\hat{\mathbf{Y}}] = E[\mathbf{Y}] = \mathbf{X}\beta \rightarrow E[\mathbf{r}] = \mathbf{0}$
- 3  $Cov(\hat{\beta}) = \sigma^2(\mathbf{X}^T \mathbf{X})^{-1}$
- 4  $Cov(\hat{\mathbf{Y}}) = \sigma^2 \mathbf{P}$ ,  $Cov(\mathbf{r}) = \sigma^2(\mathbf{I} - \mathbf{P})$

wobei  $\mathbf{P} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$

# Verteilung der Schätzer

Annahme, dass  $\epsilon$  normal-verteilt sind, daraus folgt

1  $\hat{\beta} \sim \mathcal{N}_p(\beta, \sigma^2(\mathbf{X}^T \mathbf{X})^{-1})$

2  $\hat{\mathbf{Y}} \sim \mathcal{N}_n(\mathbf{X}\beta, \sigma^2 P)$

3  $\hat{\sigma}^2 \sim \frac{\sigma^2}{n-p} \chi^2$

# Tests und Vertrauensintervalle

- Angenommen, wir möchten wissen, ob eine bestimmte erklärende Variable  $\beta_j$  relevant ist in unserem Modell, dann testen wir die Nullhypothese

$$H_0 : \beta_j = 0$$

gegenüber der Alternativhypothese

$$H_A : \beta_j \neq 0$$

- Bei unbekanntem  $\sigma^2$  ergibt sich folgende Teststatistik

$$T_j = \frac{\hat{\beta}_j}{\sqrt{\hat{\sigma}^2(\mathbf{X}^T \mathbf{X})_{jj}^{-1}}} \sim t_{n-p}$$

wobei  $t_{n-p}$  für die Student-t Verteilung mit  $n - p$  Freiheitsgraden steht.

# Probleme bei t-Tests

- Multiples Testen bei vielen  $\beta_j$ , d.h. falls wir 100 Tests mit Irrtumswahrscheinlichkeit 5% machen, sind automatisch 5 Tests signifikant
  - Es kann passieren, dass für kein  $\beta_j$  die Nullhypothese verworfen werden kann, aber die erklärende Variable trotzdem einen Einfluss hat. Der Grund dafür sind Korrelationen zwischen erklärenden Variablen
  - Individuelle t-tests für  $H_0 : \beta_j = 0$  sind so zu interpretieren, dass diese den Effekt von  $\beta_j$  quantifizieren nach Abzug des Einflusses aller anderen Variablen auf die Zielgrösse  $Y$
- falls z. Bsp.  $\beta_i$  und  $\beta_j$  stark korreliert sind und wir testen die beiden Nullhypothesen  $H_{0j} : \beta_j = 0$  und  $H_{0i} : \beta_i = 0$ , kann durch die Korrektur der anderen Variablen der Effekt von  $\beta_i$  und  $\beta_j$  auf  $Y$  durch den t-Test nicht gefunden werden.