

Vorlesung: Lineare Modelle

Prof. Dr. Helmut Küchenhoff

Institut für Statistik, LMU München

SoSe 2014

- 5 Metrische Einflußgrößen: Polynomiale Regression, Trigonometrische Polynome, Regressionssplines, Transformationen.
- 6 Modelldiagnose
- **Variablenselektion**
- 8 Das allgemeine lineare Modell: Gewichtete KQ-Methode, Autokorrelierte und heteroskedastische Störterme
- 9 Das logistische Regressionsmodell
- 10 Das gemischte lineare Regressionsmodell („Linear mixed Model“)

Navigationssymbole

Navigationssymbole

Modellwahl: Zielsetzung der Modellierung

- a) gute Beschreibung des Verhaltens der Zielgröße
- b) Vorhersage zukünftiger Werte der Zielgröße und Schätzung des Mittels der Zielgröße
- c) Extrapolation auf Bereiche außerhalb der X-Daten
- d) Schätzung von Parametern
- e) Kontrolle eines Prozesses durch Variation des Inputs
→ Kausalität nötig
- f) Entwicklung realistischer Modelle für einen Prozess
→ Kausalität nötig

Navigationssymbole

Grundsätzliches I

Allgemein: „Tradeoff“ zwischen Modell-Genauigkeit (R^2) und Einfachheit.

Viele Variablen → R^2 steigt
→ Komplexität nimmt zu

- a) b) Modellgenauigkeit wichtig
→ viele Variablen
→ Kausale Beziehung nicht nötig „Variable enthält Information“
- c) Extrapolation
→ Kausalität

Navigationssymbole

- d) Bias durch Weglassen von Variablen
Erhöhung der Varianz von Schätzern durch überflüssige Variablen

Beachte: Interpretation der Regressionskoeff. „bei Festhalten der anderen Variablen“.

→ Einschränkung durch viele Kovariablen.

- e) Kontrolle

→ Kausalität erforderlich

Realistische Beschreibung

→ Sparsames klares Modell

Kein Verfahren kann (zunächst bei den Zielen (c, d, e, f))
das Fachwissen ersetzen

→ Verfahren eher explorativ.

Bei der Prognose können bei größeren Datenmengen
Variablenselektionsverfahren sehr effizient sein.

Weitere Aspekte

- 1 Diskrete Variablen bereiten zusätzliche Probleme:

Gleiches gilt für Interaktionseffekte

Es gibt „Regeln“ z.B.,

- a) Interaktionen nicht ohne Haupteffekte ins Modell
- b) Effekte von kategoriellen Variablen nur als Ganzes ins Modell

Aber andere Möglichkeit: Verwenden von Indikator-Variablen

→ Indikator-Variablen, die nicht im Modell sind, entsprechen der
gemeinsamen Referenzkategorie

- 2 Multikollinearität kann ein erhebliches Problem sein.

→ Korrelation der Kandidaten - Einflussgrößen analysieren

- 3 Transformation, quadratische Terme liefern weitere Möglichkeiten

Maße für die Modellgüte I

Gegeben sei das lineare Modell $Y = X\beta + \varepsilon$

- a) Bestimmtheitsmaß:

$$R^2 = \frac{SSM}{SST} = 1 - \frac{SSE}{SST} \quad (7.1)$$

- b) Adjustiertes Bestimmtheitsmaß:

$$R_{adj}^2 := 1 - \frac{MSE}{MST} = 1 - \frac{\hat{\sigma}^2}{SST/(n-1)} \quad (7.2)$$

c) Akaikes Informationskriterium

$$AIC = n \ln(SSE) + 2p' - n \ln(n) \tag{7.3}$$

Ausgleich zwischen Anpassung (SSE) und Komplexität (2p')

d) Schwarz'sches Bayes-Kriterium SBC (=BIC)

$$SBC = n \ln(SSE) + \ln(n)p' - n \ln(n) \tag{7.4}$$

Komplexität wird stärker gewichtet als bei AIC

e) Mallows Cp

$$C_p = \frac{SSE}{\hat{\sigma}_G^2} + 2p' - n \tag{7.5}$$

$\hat{\sigma}_G$: Schätzung aus vollem Modell

Variablenselektionsverfahren I

Gegeben ist eine Zielgröße Y und mehrere mögliche Einflussgrößen $x_k, k = 1, \dots, K$. Gesucht ist ein möglichst gutes Modell

$$Y = \beta_0 + \sum_{j=1}^L \beta_j x_{k_j},$$

wobei die $x_{k_l}, l = 1, \dots, L$ ausgewählt werden sollen.

1 Auswahl nach einem Kriterium

Wähle aus allen möglichen 2^k Modellen das Modell mit optimalem Kriterium C aus. C ist in der Regel ein Kriterium aus (7.1) - (7.4).

Variablenselektionsverfahren II

2 Vorwärtsselektion

- a) Wähle im Anfangsschritt das Modell $Y = \beta_0$.
- b) Im ersten Schritt wird die Variable in das Modell aufgenommen, die zu dem höchsten R^2 führt.
- c) In den weiteren Schritten wird jeweils eine Einflussgröße in das Modell zusätzlich aufgenommen. Es wird jeweils die Variable, die zu dem höchsten R^2 des resultierenden Modells führt, aufgenommen.
- d) **Stoppregel:** Die Prozedur wird beendet, falls ein bestimmtes Zielkriterium erfüllt ist, z.B. AIC

3 Rückwärts-Selektion

- a) Wähle im Anfangsschritt das volle Modell $Y = \sum_{k=0}^K \beta_k x_k$
- b) In den weiteren Schritten wird jeweils eine Einflussgröße aus dem Modell genommen. Es wird jeweils die Einflussgröße, die zu dem höchsten R^2 des resultierenden Modells führt, ausgeschlossen.
- c) **Stoppregel:** Nach bestimmtem Zielkriterium, z.B. AIC.

4 Schrittweise Selektion:

Kombination aus Vorwärts- und Rückwärtsselektion. Er wird eine Vorwärtsselektion und nach jedem Schritt eine Rückwärtsselektion mit geeignetem Stoppkriterium durchgeführt.

- Möglichst inhaltlich sparsames (Maximal-)–Modell vorgeben
- Stat. Tests **nach** Variablenselektion nicht durchführbar
- Strategie bei zentraler Einflussgröße
 - Variablenselektion für „Confounder“-Modell ohne zentrale Einflussgröße
 - Test auf Effekt der zentralen Einflussgröße mit dem gewählten Confounder-Modell
- Prognoseintervalle etc. mit Kreuzvalidierung (evtl. unter Einbeziehung der Selektion)

Ausblick

- Es wurden in den letzten Jahren Methoden entwickelt, die Modellschätzung und Variablenselektion simultan erreichen: LASSO und Boosting-Verfahren, siehe Vorlesung Generalisierte Regression bzw. Fahrmeier et al (2013).
- Es gibt in der Regel nicht einfach ein bestes Modell, sondern mehrere passende Modelle. Bayes- Verfahren ermöglichen Inferenz dazu durch Berechnung von Wahrscheinlichkeiten für bestimmte Modelle.
- Eine Strategie in der Inferenz und Prognose besteht in dem sog. Model- Averaging: Man bestimmt Prognosen aus mehreren Modellen als gewichtetes Mittel der Einzel-Prognosen.